

aumentou rapidamente com a quebra da ferramenta. No domínio das frequências, uma análise revelou formação de picos que indicam uma fratura na aresta da broca. O autor sugere que uma combinação das duas técnicas é possível para monitorar de modo consistente o processo de furação.

Dan e Mathew (1990) empregaram um método de modelagem discreto chamado “*Dependent System*” para correlacionar os sinais de vibração com o desgaste de uma ferramenta. A implementação deste método envolveu a seleção de alguma banda do sinal que fosse representativo do desgaste. Os resultados obtidos mostraram que uma variação na parcela da energia de vibração de uma banda de frequência foi consistentemente observada, independentemente da influência da variação dos parâmetros de corte no sinal. A aplicação de uma análise do espectro mostrou que há uma relação linear entre a velocidade de corte e o desgaste, revelando que o sinal de vibração foi sensível ao desgaste da ferramenta.

Pesquisas sobre o comportamento do sinal de vibração com relação ao estado de desgaste de uma ferramenta no corte interrompido foram realizadas por Rotberg et al. (1987). Os autores procuraram enfatizar a entrada e a saída da ferramenta no fresamento e também medições do desgaste de flanco e de cratera. Também separaram o desgaste da ferramenta em três fases (afiada, meia vida, desgastada) e estabeleceram uma descrição destas fases via espectro. Esta descrição, via meticuloso processamento do sinal adquirido, mostrou ser um bom indicador do estado da ferramenta durante sua vida.

Jiang et al. (1987) investigaram os efeitos das vibrações na direção de corte e de avanço no desgaste da ferramenta. Os autores empregaram condições fixas de corte, uma pastilha P10 com superfície de saída plana e passadas de 10 minutos, na qual a ferramenta sofria um desgaste progressivo até acontecer uma falha catastrófica. Após o processamento dos sinais adquiridos, um espectro de frequências foi construído. Neste, foram observados três bandas de frequências sensíveis à evolução do desgaste: acima de 110 Hz, entre 117 e 510 Hz e entre 510 e 1000 Hz. Eles concluíram, a partir de suas investigações experimentais, que a vibração foi sensível aos diferentes estados de desgaste ao longo da vida de uma ferramenta.

O comportamento estático do desgaste é governado pelas forças de corte e pelo torque no eixo-árvore e o comportamento dinâmico envolve vibração e certos aspectos dinâmicos das forças de corte (Dimla, 1998). Com isto, o autor afirma que a combinação entre sinais de vibração e das forças de corte é uma ferramenta útil no desenvolvimento de sistemas de monitoramento do estado da ferramenta mais consistentes.

Dos Santos (2001) realizou um trabalho em que usou alguns parâmetros de entrada (velocidade de corte, profundidade de corte, avanço, percurso de avanço, potência e a vibração adquirida em dois pontos da máquina-ferramenta) para realizar o treinamento de uma rede neural *feedforward* com um algoritmo de aprendizado *backpropagation*. O objetivo da pesquisa

foi monitorar o desgaste de flanco máximo e a rugosidade Ra. Em uma análise gráfica qualitativa, a vibração aparece com uma tendência de comportamento mais definida em relação ao desgaste da ferramenta do que com a rugosidade Ra. Porém, ao analisar a sensibilidade dos parâmetros de entrada da rede, verificou que o parâmetro vibração contribuiu para o aumento dos erros da rede quando esta estima o valor do desgaste. O autor explica que o aumento dos erros verificados ao se empregar o parâmetro vibração na estimação do desgaste se deve à elevada correlação desse parâmetro com as demais variáveis do processo, o que torna mais difícil o processo de treinamento da rede neural devido à redundância de informações.

No monitoramento da usinagem através do sinal de vibração, é também muito importante conhecer o comportamento dinâmico da máquina-ferramenta. Sousa (1993) realizou um mapeamento dos locais mais apropriados para o acoplamento dos acelerômetros em uma fresadora CNC Romi Interact 4 usada em seus experimentos. Para isto, ele determinou 80 possíveis locais de acoplamento do sensor na fresadora. A partir daí, foi realizada uma análise de sensibilidade utilizando-se Funções de Resposta em Frequência (FRF). Após esta análise, o autor verificou que muitos dos locais de acoplamento apresentavam características dinâmicas muito semelhantes, permitindo reduzir os possíveis pontos a vinte e nove, sendo a maioria próxima do mancal inferior do eixo porta fresa e na mesa de trabalho e um na própria peça a ser usinada.

2.3.4 Monitoramento da usinagem através dos parâmetros elétricos do motor

É um método bastante simples, de baixo custo e não intrusivo, pois fica instalado perto do motor e longe da região de corte. Segundo Dan (1990), durante o processo de corte a potência consumida pelo motor principal da máquina aumenta com o desgaste da ferramenta de corte. Assim, quanto maior o desgaste da ferramenta, maior o esforço de corte e, conseqüentemente, maior a corrente necessária ao processo. Então, a vida da ferramenta pode ser monitorada através da análise do comportamento dos sinais elétricos do motor da máquina.

Medir os parâmetros elétricos do motor é medir indiretamente os esforços de corte (Ferraresi, 1977). Este fato se explica, pois o motor da máquina-ferramenta, para gerar a potência mecânica necessária para executar uma operação de usinagem, consome corrente elétrica em uma quantidade diretamente proporcional à potência e as forças de corte geradas.

O monitoramento através dos parâmetros elétricos do motor apresenta como principais vantagens (dos Santos, 1988):

- . É uma técnica pouco intrusiva;
- . Baixo custo, principalmente se comparado com outros sistemas de monitoramento;

- . Tecnologia e operação relativamente simples;
- . Fácil instalação, não necessitando nenhum projeto especial para sua adaptação;
- . Não requer muito espaço, podendo ser instalado no armário de alimentação da máquina;
- . Pode ser aplicado à maioria dos motores elétricos (AC e DC);
- . Pode realizar o monitoramento em processo (*on-line*);
- . É um bom sistema de monitoramento para operações de fresamento, pois os valores de potência são pouco sensíveis aos choques na entrada da ferramenta.

Como principais deficiências deste sistema pode-se destacar:

- . Baixa sensibilidade ao estado de desgaste da ferramenta, sendo pouco diferenciados os valores de potência entre uma ferramenta nova e uma já desgastada. Porém, quando a ferramenta apresenta elevados níveis de desgaste, este sistema de monitoramento é mais sensível (Braga, 1992).
- . Como nem toda potência elétrica consumida é transformada em potência mecânica (devido a perdas com atrito e com inércia do sistema), há uma perda de precisão no sistema de monitoramento.

Caldeirani Filho (1998) realizou um trabalho de monitoramento, através da aquisição do sinal de corrente elétrica e também de emissão acústica no processo de fresamento. Segundo o autor, a evolução do sinal de corrente elétrica apresentou um comportamento bastante similar à evolução do desgaste ao longo do percurso de avanço. O autor também sugere que a corrente elétrica do motor pode ser, aliada a outros sinais, um bom parâmetro de entrada de uma rede neural a fim de estabelecer o fim de vida da ferramenta.

Os sinais de corrente elétrica são captados pelo sensor de efeito *Hall*, que é instalado circulando um fio condutor de corrente próximo do motor, e transformados em tensão elétrica proporcional a ela para a entrada no conversor A/D – uma placa de expansão que tem por objetivo integrar o microcomputador com o meio externo. Neste caso, a placa tem a função de transformar os sinais analógicos em digitais para serem armazenados e analisados no microcomputador (Matsumoto; Diniz, 1997).

2.4 Emissão Acústica

Segundo Ravindra; Srinivasa; Krishnamurthy (1993), a emissão acústica (EA) pode ser definida como sendo ondas de tensão elástica resultante da rápida liberação de energia de uma ou mais fontes dentro de um material submetido a estímulo externo. Estas ondas vibracionais se devem a um rearranjo interno na estrutura cristalina dos metais e a frequência de propagação normalmente está acima de 20 kHz (Dolinsek; Kopac, 1999). Estas ondas de tensão produzem deslocamentos na superfície do material, podendo então ser detectadas por sensores piezelétricos que transformam estes deslocamentos em sinais elétricos.

Os sinais de emissão acústica classificam-se em dois tipos: o sinal contínuo e sinal de pico (transiente), conforme (Blum e Inasaki, 1990; Matsumoto e Diniz, 1997). O sinal de pico é caracterizado por um pico de grande amplitude e pequena duração, enquanto que o sinal contínuo tem amplitudes relativamente menores e maior duração. No caso da usinagem, o sinal contínuo normalmente está associado às deformações plásticas em materiais dúteis e o sinal de pico, oriundos da propagação de trincas e impactos do cavaco. A Figura 2.36 mostra um gráfico típico de emissão acústica para um processo de usinagem.




Figura 2.36 - Caracterização de um sinal de emissão acústica (Li, 2002).

Como consequência das faixas de frequência de EA, entre 50 a 1000 kHz aproximadamente, segundo definição de Liang e Dornfeld (1987), o sinal pode ser descontaminado de ruídos com uma certa facilidade através da utilização de um filtro passa-alta. Por outro lado, a alta frequência dificulta a amostragem e o armazenamento do sinal digitalizado durante o processo, pois em um pequeno intervalo de tempo uma quantidade muito grande de pontos deve ser adquirida para que a amostra do sinal seja confiável. Se, como exemplo, um sinal com frequência de 500 kHz for adquirido, ele tem que ser digitalizado com uma frequência de pelo menos 1000 kHz (1 MHz) para que o sinal amostrado seja representativo do sinal real. Isto significaria cerca de um milhão de pontos armazenados em 1 segundo de tempo de corte.

Os principais métodos para o processamento do sinal da EA no domínio do tempo são (Pigari, 1995):

a) Tensão RMS (V_{RMS}): é a raiz quadrada da média do quadrado da tensão do sinal de EA. É um modo de avaliar a energia contida no sinal de EA. O valor RMS do sinal de EA pode ser expresso como mostrado na Eq. (2.10) (Teti; Dornfeld, 1989):

$$V_{RMS} = \left(\frac{1}{\Delta T} \int_0^{\Delta T} V^2(t).dt \right)^{\frac{1}{2}} \quad (2.10)$$

onde:

$V(t)$ = função do sinal;

ΔT = constante de tempo

Asibu e Dornfeld (1981) propuseram, pela Eq. (2.11), um modelo que relaciona o valor do sinal RMS da emissão acústica e alguns parâmetros empregados na usinagem. Para isto, eles empregaram condições bem específicas, tais como o corte ortogonal e também criaram métodos para que as únicas fontes de EA fossem deformações plásticas na região de cisalhamento primária e secundária e o atrito entre a peça e a ferramenta na superfície de folga.

$$V_{RMS} = C \left[\tau_k w V_c \left(\frac{\cos \gamma_o}{\sin \phi \cos(\phi - \gamma_o)} t_1 + \frac{1}{3} (l - l_1) \frac{\sin \phi}{\cos(\phi - \gamma_o)} \right) \right]^{\frac{1}{2}} \quad (2.11)$$

Onde:

V_{RMS} = energia contida no sinal de EA;

C = constante;

τ_k = resistência ao cisalhamento dinâmico do material trabalhado;

w = espessura de corte;

V_c = velocidade de corte;

γ_o = ângulo de saída da ferramenta;

ϕ = ângulo do plano de cisalhamento;

t_1 = espessura do cavaco antes de ser deformado;

l = comprimento total da região de contato entre o cavaco e a ferramenta;

l_1 = comprimento da região de aderência entre o cavaco e a ferramenta.

b) Número total de picos: é o número de vezes que o sinal ultrapassa um determinado valor pré-estabelecido de tensão (*threshold*) quando o contador trabalha continuamente, sem interrupções até o final da aquisição (Beattie, 1983).

c) Taxa do número de picos: é a contagem do número de vezes que o sinal ultrapassa um determinado *threshold* pré-estabelecido dentro de um certo intervalo de tempo, geralmente entre 0,1 segundo a uma hora (Beattie, 1983).

d) Taxa de cruzamento do zero: tem a mesma definição do item anterior, porém o valor do *threshold* estipulado é o zero.

e) Desvio padrão: mede a dispersão dos dados em relação à média.

f) *Skewness*: este parâmetro mede a simetria da função densidade de probabilidade em torno da média. Um *skewness* negativo indica que a maior parte dos pontos encontra-se à esquerda da média enquanto que um *skewness* positivo indica que a maior parte dos pontos encontra-se à direita. O *skewness* é definido como o momento normalizado de terceira ordem da distribuição da amplitude e seu cálculo é dado pela Eq. (2.12):

$$S = \frac{M_3}{(M_2)^{\frac{3}{2}}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{3}{2}}} \quad (2.12)$$

onde:

M_2 = momento de segunda ordem da distribuição;

M_3 = momento de terceira ordem da distribuição.

g) Curtose: este parâmetro mede a dispersão da função densidade de probabilidade. Um valor de curtose alto indica pequena dispersão dos pontos e um valor de curtose pequeno indica que os pontos estão mais espaçados. Curtose é definida como o momento normalizado de quarta ordem da distribuição de amplitude e seu cálculo é dado pela Eq. (2.13):

$$K = \frac{M_4}{(M_2)^2} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^2} \quad (2.13)$$

onde:

M_4 = momento de quarta ordem da distribuição.

h) Função autocorrelação: é a medida do nível de semelhança de um sinal com outro sinal defasado e de mesma forma de onda a fim de se identificar os componentes periódicos presentes no sinal. Esta função é usada, algumas vezes, para diferenciar uma informação desejada (som, imagem ou dados) de um ruído. A Equação 2.14 determina a correlação entre observações separadas por um atraso k e r_k é o coeficiente de auto-correlação destes sinais.

$$r_k = \frac{\sum_{i=1}^{N-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (2.14)$$

i) Análise da distribuição de amplitude: é a indicação do número de sinais cuja amplitude cai numa faixa pré-definida. Vários valores são escolhidos e o número de eventos que ocorre em cada intervalo padrão é identificado.

Um dos métodos para o processamento do sinal de EA fora do domínio do tempo é o espectro de freqüências, que é composto por um infinito número de parâmetros (cada freqüência possui sua própria amplitude), auxiliando na caracterização das fontes dos fenômenos. O procedimento matemático para o cálculo do espectro de freqüência é a transformada rápida de Fourier (FFT), comumente usada em processamento de sinal de EA (Naerheim; Lan, 1988).

A análise do espectro de freqüência pode ser muito útil no monitoramento do desgaste da ferramenta e da rugosidade da superfície usinada. Dolinsek e Kopac (1999) em seu trabalho, empregando um sensor *water-jet* de EA, parâmetros de corte para acabamento e ferramentas de *cermet* e metal duro revestidas com TiN, verificaram que a faixa de freqüência sensível ao desgaste da ferramenta estava entre 100 kHz e 610 kHz e também mostram, como ilustra a Fig. 2.37, as freqüências que foram sensíveis aos diferentes estados de desgaste das ferramentas.




Figura 2.37 - Espectros de frequência do sinal de EA para diferentes níveis de desgaste de flanco (Dolinsek; Kopac, 1999).

Rangwala e Dornfeld (1991-parte 2), empregando torneamento com corte ortogonal, mostraram que a análise do espectro de frequência aponta um direcionamento do conteúdo (informações contidas no sinal de EA) para as altas frequências quando as velocidades de corte são aumentadas. Porém, a partir de um certo valor limite de velocidade de corte, há uma mudança da direção da energia do sinal para as baixas frequências devido ao efeito do amolecimento do material causado pelo aumento das temperaturas na região de corte. O efeito do avanço sobre a frequência média (f_m), causando uma diminuição de seus valores, só foi percebido a maiores velocidades. A frequência média, que divide o espectro em duas partes iguais, é calculada conforme Eq. (2.15). O aumento do comprimento de contato entre a ferramenta e o cavaco causou um aumento da frequência média e foi atribuído ao aumento da região de escorregamento na interface cavaco ferramenta.

$$f_m = \frac{\sum_{i=1}^n S_i f_i}{\sum_{i=1}^n S_i} \quad (2.15)$$

Onde:

S_i = energia do sinal de EA a uma frequência i ;

f_i = frequência qualquer que compõe o espectro;

n = número de frequências em que o espectro é construído.

2.4.1 Monitoramento da usinagem através da emissão acústica

As principais fontes de emissão acústica na usinagem, mostradas na Fig. 2.38, são: o atrito cavaco-ferramenta, o atrito ferramenta-peça, a deformação da peça e a deformação e quebra do cavaco. Como o desgaste da ferramenta influencia todas estas fontes, seu aumento pode ser medido indiretamente pela medição de EA (Dornfeld, 1988).




Figura 2.38 - Fontes de emissão acústica durante a usinagem (Li, 2002).

Segundo Lee et al. (2005), em usinagem de precisão, a EA pode ser atribuída a várias fontes na interface cavaco-ferramenta, como mostrado na Fig. 2.39. Segundo os autores, as fontes de EA, para a usinagem tradicional, são tipicamente geradas na zona de cisalhamento primária (região de cisalhamento situada imediatamente à frente da aresta de corte), na zona de cisalhamento secundária (região de contato entre o cavaco e a superfície de saída da ferramenta) e na região situada entre a superfície de usinagem e a superfície de folga da ferramenta. Para uma escala de espessura de corte da ordem de dezenas de micrômetros ou mais, grande parte do sinal é devido ao atrito e a fricção que ocorrem na zona de cisalhamento secundária e na região de contato da superfície de folga com a superfície em usinagem. Para uma usinagem de ultraprecisão, estes autores acreditam que a maior parte da geração de sinal de EA é originada através da interação da ponta da ferramenta com aspectos microestruturais

da peça, tais como vazios, inclusões, contornos de grão e deslocamentos de aglomerações de discordâncias na zona de cisalhamento primária.




Fig.2.39 – Fontes de emissão acústica para algumas escalas de espessura de corte (Lee et al., 2005).

Para representar experimentalmente as aplicações da EA, estes últimos autores realizaram um trabalho de torneamento de precisão em que usinaram uma peça de cobre OFHC policristalino que tem grãos com média de $250 \mu\text{m}$ de diâmetro. Em um mapa polar de intensidade luminosa montado com o sinal de EA, viu-se a boa correlação que este tem com a micrografia desta superfície após o ataque, como pode ser visto na Fig. 2.40. Com isto, eles concluíram que a técnica do mapa polar de EA além de servir como um sensor de contato da ferramenta, fornece meios de detecção de pontos ou áreas defeituosas na peça.




Figura 2.40 – (a) Mapa polar do sinal de EA_{RMS} para uma peça de cobre OFHC policristalino usinada pelo processo de torneamento de precisão. (b) Micrografia da mesma peça quimicamente atacada (Lee et al., 2005).

A emissão acústica tem sido usada para atingir vários objetivos em processos de usinagem. É usada no estudo dos fundamentos do processo de usinagem, como por exemplo, os mecanismos de formação do cavaco e também na investigação de alguns fenômenos de geração de energia no corte (cisalhamento e deformação plástica do cavaco além dos atritos contra as superfícies de folga e saída da ferramenta). Outra área onde a emissão acústica tem sido intensivamente investigada é no monitoramento *on-line* do desgaste da ferramenta e na detecção de fratura, tanto no torneamento como no fresamento. Na retificação, a EA é usada na operação de *spark-out*, vida do rebôlo, dressamento, controle de avanço e detecção do contato (Diniz, 1992).

No torneamento de acabamento, o aumento da rugosidade superficial pode ser também causado pelo aumento do desgaste da ferramenta. Como o desgaste tem sido objeto de estudo através de EA, esta também pode ser útil no monitoramento da rugosidade. A Figura 2.41 mostra a faixa de frequências (200 a 300 kHz) que foi mais sensível à evolução do desgaste e ao aumento da rugosidade (Diniz; Liu; Dornfeld, 1992).

No monitoramento do desgaste da ferramenta, a EA vem sendo bastante utilizada devido a importantes vantagens como (Dornfeld, 1988):

- . Custo relativamente baixo;
- . Dimensões reduzidas do sensor, o que o torna de fácil instalação e pouco intrusivo;
- . Faixas de frequência de aproximadamente 50 a 1000 kHz, um nível muito acima de vibrações mecânicas ou outros ruídos que estão envolvidos em um ambiente de manufatura.




Figura 2.41 - Evolução do sinal de EA no tempo e na frequência (Diniz, 1992).

Entretanto, o monitoramento da evolução do desgaste apresenta certas dificuldades, como a combinação do desgaste de flanco com o desgaste de cratera. É consenso o fato que o crescimento do desgaste de flanco implica no crescimento dos níveis do sinal de EA, devido ao aumento do contato entre a superfície de folga e a peça, resultando em um aumento do atrito nesta região. Mas também é consenso que, como o desgaste de cratera gera um aumento no ângulo de saída da ferramenta, facilitando assim o corte, este tipo de desgaste produz uma diminuição nos níveis do sinal de EA.

No fresamento, os sinais de pico são normalmente observados quando ocorrem a quebra do cavaco, quebra ou lascamento da ferramenta e na entrada e saída do ciclo ativo da ferramenta, enquanto os sinais contínuos decorrem da deformação plástica do material da peça e do cavaco. Portanto, fatores como a quebra e o lascamento da ferramenta e a quebra do cavaco são facilmente identificáveis, como citado anteriormente, pela presença repentina de picos de EA, seguidos de mudanças na intensidade do sinal (Lan; Dornfeld, 1984). Por outro lado, o desgaste da ferramenta é mais difícil de detectar devido à baixa intensidade do sinal, a presença de fontes de ruídos e sua dependência com os parâmetros de corte (Ravindra et al., 1997).

No brochamento, Axinte et al. (2004) mostram que um aumento na magnitude por volta de 110 kHz pode ser notado e isto pode ser creditado ao aumento das deformações plásticas associadas à formação do cavaco quando mais de um dente está cortando a peça simultaneamente.

Baseado nesta informação, uma análise do espectro de frequências foi feita para o último dente da brocha, quando este é o único a tocar na peça. Como este dente tem a função de alisar a superfície, a baixa magnitude do sinal de EA a 110 kHz sugere que este dente

realmente apenas toca a superfície e não há nenhum corte. Conseqüentemente, nenhum pico de sinal é detectado nem na entrada nem na saída deste dente.

Em uma região onde dois ou três dentes estão cortando simultaneamente, o sensor de EA pode adquirir eventos específicos gerados pelo contato destes com a peça. Porém, é difícil identificar de qual dente este evento advém. Por isto, qualquer pico de sinal que aparecer nesta região durante o corte pode não ter a origem facilmente identificável.

Na brocha, mesmo tendo todos os dentes a mesma preparação, algumas diferenças podem ser notadas entre o espectro dos picos de sinal gerados na entrada e na saída do corte de cada dente. Este fato deve ocorrer, segundo os autores, devido a uma combinação de fatores: diferentes carregamentos por dente, diferentes níveis de desgaste e também pequenas diferenças na preparação das arestas. Análise de frequência dos picos de sinal de EA associados à entrada/saída do dente na peça mostram diferentes comportamentos, especialmente quando se empregam ferramentas desgastadas.

Caldeirani Filho (1998) monitorou o fresamento através do sinal de EA_{RMS} e corrente elétrica do motor. Ao comparar os dois sinais com a evolução do desgaste da ferramenta, da maneira como estes sinais foram processados no trabalho, este concluiu que o sinal de corrente é o que acompanha melhor a evolução do desgaste. Segundo o autor, o sinal de EA é influenciado não só pela evolução do desgaste, mas também por outros fenômenos que acontecem durante o corte, fazendo com que a EA não acompanhe o crescimento do desgaste. Somente quando o valor do desgaste já é alto e a ferramenta já está bem próxima do final de vida (quando o critério de fim de vida permita que o desgaste atinja valores elevados) é que o sinal de emissão acústica apresenta alguma variação, diminuindo a possibilidade de tomada de decisão quanto à substituição da ferramenta.

A maioria das pesquisas realizadas adquirindo-se sinal de emissão acústica utiliza filtro RMS devido à sua relativa facilidade de processamento. Porém, este método de aquisição implica na perda de valiosas informações do sinal de EA. Além disso, os sinais adquiridos pelo sensor de EA são freqüentemente distorcidos por ecos, ressonâncias e por um acoplamento inadequado. Nestes casos, normalmente se usam ferramentas de deconvolução para predizer o sinal real emitido pelo processo (Webster et al., 1994).

Segundo Webster et al. (1994), o filtro RMS é aplicado como um filtro contínuo em várias janelas ao longo de todo o sinal bruto, portanto, ele não representa apenas um único valor médio do conjunto.

Oliveira e Dornfeld (2001) realizaram pesquisas com o sinal EA_{RMS} na retificação. Os autores usaram o sinal para criar um mapa de intensidade luminosa que se revelou muito útil na avaliação de alguns aspectos da retificação. Com o mapa eles conseguiram reproduzir e avaliar o dressamento, a topografia do rebôlo e o próprio processo de retificação.

A média de energia do sinal RMS da emissão acústica tem mostrado boa sensibilidade à velocidade de corte, dureza do material da peça e a lubrificação, mas é altamente afetado pela profundidade de corte e avanço no torneamento. Resultados similares podem ser tirados do fresamento, mas algumas considerações especiais devem ser feitas (Diei, 1984):

- . A natureza descontínua do corte introduz duas fontes adicionais de EA, uma na entrada e outra na saída da ferramenta da peça. O nível dos sinais nestas regiões é maior, o que resulta em picos do sinal de EA_{RMS} ;
- . A espessura do cavaco varia durante cada ciclo, gerando uma variação nas forças e nas condições de contato na superfície de saída;
- . Na saída da ferramenta, cavacos eventualmente podem aderir na ferramenta e são levados para a próxima entrada, causando um congestionamento de cavaco. Isto introduz variações aleatórias no nível e características do sinal gerado;
- . Em uma ferramenta multicortante, mais de uma aresta pode estar cortando ao mesmo tempo, implicando em altos níveis e mistura de sinais das arestas.

Webster et al. (1994) sugerem que, durante a retificação, o sinal de EA adquirido pode ser bem diferente daquele que acontece na região de corte. Razões para este fato incluem ecos, ressonâncias do sensor e também devido ao tipo de filtro passabanda aplicado, que podem alterar as características das ondas de deformação que propagam da zona de corte para o sensor. Este problema pode ser amenizado, segundo os autores, usando-se um filtro adaptivo. Este filtro é chamado RLS (*Recursive Least Square Filter*), no qual é implementado como um equalizador adaptivo. Um benefício significativo do filtro RLS é que pode ser usado para separar sinais de curta duração das distorções listadas acima.

O filtro adaptivo RLS trabalha o sinal de forma a produzir um sinal onde os impulsos não têm grande comprimento e, também, as propriedades tonais do sistema (por exemplo, o conjunto peça-sensor), através do qual o sinal propaga, sejam equalizadas. Então, o filtro RLS é implementado como um equalizador adaptivo e também como um inibidor de ecos.

Um filtro adaptivo RLS opera da seguinte forma (Webster et al., 1994):

- . Um sinal aleatório momentâneo (impulsivo) percorre a peça até a região de contato;
- . Este sinal torna-se distorcido ao passar para o sensor, através do sensor e pelo filtro passabanda;
- . A saída é armazenada em um sistema de aquisição de dados;
- . O sinal medido é constituído por uma parte tonal e outra estocástica;
- . A necessidade é separar a parte tonal (proveniente do sistema de aquisição) da parte estocástica (proveniente da usinagem);
- . São escolhidos então adequados comprimento de usinagem e fator de esquecimento;

- . Cada interação do filtro com os valores do sinal medido são usados para otimizar a predição de seu valor futuro (pelo método dos mínimos quadrados);
- . O sinal predito é subtraído do sinal medido levando a predição da sequência de erro;
- . Os parâmetros do filtro são atualizados a fim de minimizar a sequência do erro.

O sinal predito obtido do sinal bruto de EA combina bem com o sinal medido, indicando que o sistema de medição causa uma certa alteração no sinal originário do processo. Dados que contenham eventos tais como uma formação de trinca na superfície são evidenciados pelo filtro RLS. Sendo assim, este filtro é especialmente eficaz em detectar eventos transientes. Os autores deste trabalho acreditam que estes picos de liberação de energia, detectados apenas pelo filtro RLS, são resultantes da liberação de energia de deformação oriundas da trinca.

Neste mesmo trabalho, os autores também afirmam que um sistema de aquisição de sinais via EA com um filtro curtose é mais fácil de ser acomodado em uma máquina de produção que uma célula de carga usada para medições de carga. O sistema de aquisição de EA é também mais indicado que o sistema de aquisição de potência na retificação, pois sua resposta aos eventos ocorridos no processo de corte é muito mais rápida.

Resultados experimentais mostrados por Kannatey-Asibu e Dornfeld (1986) indicam que o aumento do desgaste da ferramenta resulta em um aumento do parâmetro *skewness* e uma diminuição do parâmetro curtose.

Blum e Inasaki (1990) procuraram relacionar, em seu trabalho realizado no corte ortogonal, a emissão acústica e parâmetros de corte para tentar identificar a proporção de cada fonte de EA originadas nas zonas de cisalhamento primário e secundário. Para isto, foi realizada também a aquisição da força, na qual foram relacionadas com a taxa de consumo de energia durante o corte nas zonas de cisalhamento já citadas. Através destas taxas de consumo de energia, foram realizadas comparações com o sinal de EA. O parâmetro usado para tratar o sinal de EA foi o *EA-mode*, que retira os valores intermitentes da aquisição, sobrando apenas o sinal contínuo. Os resultados mostraram boa correlação do sinal de EA com a energia consumida quando se varia a velocidade de corte, mas o mesmo não se verificou quando foi variado o avanço, o ângulo de saída da ferramenta e a profundidade de corte. Quando o sinal de EA é comparado com o desgaste de flanco, a EA mostrou uma relação melhor que as energias consumidas. Segundo estes autores, o nível de crescimento do sinal de EA é tão intenso que permite concluir que o desgaste de flanco não é originário apenas da abrasão, mas também de mecanismos como a adesão além da forte contribuição das severas condições (tais como elevados gradientes de temperatura e tensão) na fronteira entre a superfície da peça e a superfície de folga da ferramenta.

Segundo Dimla (2000), a EA gerada durante o corte é bem menor que a EA gerada quando ocorrem trincas ou fraturas na ferramenta. Portanto, uma das principais deficiências da aplicação da emissão acústica como indicador do estado da ferramenta está no fato que seu sinal é bem mais sensível às variações no ajuste das condições de corte e aos ruídos do que às condições da ferramenta.

Já Blum e Inasaki (1990) concluíram que, embora retirar informações sobre o estado do desgaste da ferramenta através dos sinais de EA seja uma tarefa difícil, a alta sensibilidade destes sinais os tornam superiores para esta tarefa que o monitoramento através dos sinais de força.

2.4.2 Considerações a respeito de sensores de emissão acústica.

Normalmente, as aquisições de sinais de EA são realizadas por sensores piezoelétricos, mas diferentes tipos sensores para esta finalidade estão disponíveis. Porém, apenas alguns deles podem ser usados em uma máquina-ferramenta onde é comum encontrar um ambiente agressivo. As principais desvantagens dos sensores são que eles foram projetados para inspeções não-destrutivas ou para trabalhos de pesquisa e, portanto, eles podem não suportar agressões como altas temperaturas, grandes volumes de fluidos de corte e a abrasividade de colisões com o cavaco. Também é esperado de um sensor usado no monitoramento da usinagem que ele seja sensível a todas possíveis fontes de EA (Dolinsek e Kopac, 1999).

Dolinsek e Kopac (1999) apresentam um novo conceito de sensor, o sensor *water-jet* de EA. Este usa um jato de algum líquido, que pode ser um refrigerante, como meio de transmissão dos sinais de EA para o elemento piezoelétrico. Sendo pequena a distância entre a região de corte e o elemento transdutor, o efeito de amortecimento é minimizado e a razão entre o sinal e ruído melhorado.

Norman (2003), em sua dissertação de mestrado, afirma que é possível adquirir o sinal de emissão acústica sem que haja nenhum contato entre o sensor e a peça ou a ferramenta. Isto pode ser realizado através de um sensor *Laser Doppler Velocimetry* (LDV). Este sensor funciona enviando feixes padrões de laser (em x e em y) contra a superfície e processando as diferenças ao receber o sinal de volta.

Com relação à fixação do sensor de EA, Iwata et al (1977) afirmam que, nas operações de fresamento, deve ser feita na própria peça a ser usinada, pois a atenuação do sinal em função de sua localização em relação à distância de corte é insignificante.

Já Webster et al. (1994) perceberam durante seus ensaios experimentais que, com o posicionamento do sensor de EA na peça, o sinal irá crescer quando a ferramenta estiver cortando próxima do sensor. Porém, este problema não é simples de resolver. Uma possível solução para que a distância da região de corte variável não influencie na intensidade do sinal

de EA, no caso do fresamento, é colocar o sensor na torre da máquina-ferramenta. Esta solução mantém a distância sensor-fontes de emissão acústica constante. Contudo, ao se posicionar o sensor nesta região, algumas importantes frequências do sinal podem ser perdidas, devido à ação de rolamentos, que atuam como filtros. Estes autores apresentaram como solução para atenuar este problema da variação da distância sensor-fonte e o efeito dos rolamentos na aquisição dos sinais de EA na usinagem o uso de um fluido de acoplamento na interface com a peça.

Beattie (1983) também afirma que uma fina película de algum fluido acoplante melhora a qualidade do sinal na interface do sensor com a superfície da peça. Segundo o autor, isto ocorre porque, como a onda acústica pode ser tratada como uma onda de pressão que se transfere entre o contato de duas superfícies (sensor e peça). Assim, o fluido acoplante aumenta a área de tensão e transfere uniformemente as ondas entre as duas superfícies.

2.4.3 Considerações sobre o ruído no sinal de emissão acústica

Existem diferentes ruídos que aparecem em qualquer sinal adquirido e que devem ser identificados, atenuados ou mesmo eliminados. No caso da emissão acústica, o ruído mecânico (resultado da vibração dos componentes da máquina-ferramenta) é o que apresenta maior amplitude e aparece em frequências abaixo de 100 kHz. Neste sentido, a filtragem no sinal (no caso, através de um filtro passa alta) deve ser realizado antes de qualquer amplificação (para não fortalecer este tipo de ruído). Ruídos eletromagnéticos com frequências acima de 1 MHz são eliminados com a implementação de filtros passa baixa (Jemielniak, 2001). A Figura 2.42 mostra a cadeia de instrumentação para aquisição do sinal de EA na usinagem.




Figura 2.42 – Cadeia de instrumentação de um sinal de EA em usinagem (Jemielniak, 2001).

2.5 Redes Neurais Artificiais (RNA)

A verificação das condições de desgaste da ferramenta pode ser realizada via informação sensorial através do operador. Estas informações podem ser detectadas através da visão, da audição e até mesmo pelo olfato. O operador com boa experiência é capaz de realizar associações de um ou mais de seus sentidos com padrões empíricos do desgaste. Contudo, com o avanço tecnológico de máquinas ferramentas e ferramentas de corte, a necessidade de uma consistente melhoria na produtividade e o aumento da competitividade entre fabricantes fez do monitoramento dos processos e uma posterior tomada de decisão com rapidez e confiabilidade tornarem-se fundamentais.

Alguns dos métodos empregados para a tomada de decisão com relação ao andamento do processo são: reconhecimento de padrões, a lógica “Fuzzy”, árvores de decisão ou Redes Neurais Artificiais. Destes métodos, a Rede Neural Artificial (RNA) é um dos mais utilizados na usinagem devido a algumas de suas características que serão descritas no decorrer deste capítulo.

Através de uma analogia com o funcionamento do cérebro humano, foram criadas na década de 40 as Redes Neurais Artificiais (Pitts, 1943). Na usinagem, basicamente, uma RNA é treinada através de informações recebidas por sensores de monitoramento do processo acoplados à máquina ferramentas, tornando-a capaz de classificar, por exemplo, a condição de desgaste de uma ferramenta de corte.

Abordando de uma maneira mais detalhada, as RNAs consistem de uma rede de elementos de processamento de sistemas altamente não lineares em paralelo. Estes elementos são chamados neurônios, sendo que alguns são acessíveis para estímulos de entrada, outros permitem acessos às suas saídas e outros não são acessíveis, como mostrado na Fig. 2.44. As redes neurais artificiais têm tido grande aplicabilidade em sistemas não lineares de difícil solução por métodos tradicionais. Seu emprego para identificação, reconhecimento de padrões, classificação e modelamento em processos de corte vem obtendo excelentes resultados.

O procedimento neurocomputacional empregado nas RNAs tem duas diferenças básicas que o caracteriza e que o diferencia em relação aos algoritmos sequenciais convencionais. A primeira é a capacidade de aprendizado através de exemplos e sem percepção prévia e explícita de conhecimentos (comportamento físico do processo), exceto pelo tratamento adequado dos dados de entrada. A segunda é a capacidade, após o treinamento, de generalizar durante a operação, fazendo com que ela seja capaz de responder corretamente a novos e desconhecidos estímulos, desde que pertençam ao mesmo domínio de estímulos empregados no treinamento.




Figura 2.44 – Rede Neural *FeedForward* Multicamadas.

2.5.1 Considerações sobre uma rede biológica

As primeiras tentativas de se fazer uma analogia entre o funcionamento da rede de neurônios de um cérebro humano e um processamento computacional foram idealizados no início dos anos 40, em uma cooperação entre o psiquiatra e neuroanatomista McCulloch e o matemático Walter Pitts (1943).

O cérebro humano possui certas características que não estão presentes nos computadores com arquitetura centralizada de Von Neumann e mesmo em computadores paralelos modernos (Jain; Mao, 1996). Dentre estas características, pode-se citar:

- . capacidade de aprendizado;
- . capacidade de generalizar;
- . capacidade de adaptação;
- . paralelismo;
- . baixo consumo de energia;
- . e também é responsável por outras características do ser humano, tais como emoção, percepção, cognição além de controlar as funções motoras e autônomas.

Portanto, o que se espera da neurocomputação ou computação neural é que esta possua algumas das características e habilidades do cérebro humano. Problemas com reconhecimento de padrões, predição, otimização, memória associativa e controle são algumas das características que as RNAs possuem que podem ser associadas com o cérebro humano.

O neurônio biológico ou célula nervosa processa toda a informação que chega ao cérebro. Estas células são compostas por três seções: o corpo da célula e por dois braços, o axônio e os dendritos. Estes têm funções específicas e complementares. O corpo da célula é constituído de um núcleo e um plasma. O corpo carrega informações a respeito da natureza hereditária e o plasma produz material necessário ao neurônio. As informações e impulsos oriundos de outras células são recebidos e conduzidos até o corpo pelos dendritos. Ao chegar ao corpo celular, estas informações são processadas e então novos impulsos são gerados. O axônio (que funciona como um transmissor) se encarrega de transmitir estes impulsos em ramificações que podem se constituir de filamentos ou subfilamentos (dos Santos, 1998).

O córtex cerebral humano contém cerca de 10^{11} neurônios massivamente conectados sendo cada neurônio conectado com 10^{13} a 10^{14} outros neurônios das cerca de 10^{14} a 10^{15} interconexões do cérebro. Estes neurônios se comunicam através de um curto (duração de milissegundos) trem de pulsos. A comunicação é modulada na frequência de transmissão de pulsos, que é algumas poucas centenas de *hertz*. Entretanto, em poucos milissegundos, um número elevado de decisões podem ser realizadas. Isto quer dizer que o cérebro humano processa um programa paralelo que está em torno de 100 passos para realizar uma tarefa de percepção. Como é tido que cada neurônio transmite a outro uma informação de poucos bits, esta informação é capturada e distribuída nas interconexões, e não diretamente transmitida.

2.5.2 Modelo genérico de um neurônio artificial

Uma RNA típica consiste de um sistema dinâmico que possui unidades de processamento (neurônios) interligadas de maneira lógica e em forma de camadas. Estas camadas de neurônios apresentam três níveis: uma camada hipotética de entrada, onde os dados são apresentados à rede mas não há nenhum processamento; uma ou mais de uma oculta onde os dados são processados; e uma camada de saída, que apresenta os resultados fornecidos pela rede.

Um neurônio artificial da rede, no modelo proposto por McCulloch-Pitts (1943), funciona com duas fases de processamento. Em uma primeira fase, é calculado o somatório do produto das entradas advindas das camadas prévias pelos pesos associados. Em seguida, na segunda fase, uma função não linear, denominada função de ativação, é aplicada ao resultado do somatório da fase preliminar. No modelo de McCulloch-Pitts, a função de ativação é dada pela função descrita na Eq. 2.16.

$$\sum_{i=1}^n x_i w_i \geq \theta \quad (2.16)$$

Onde n é o número de entradas do neurônio, x_i é a entrada e w_i seu peso associado e θ é o limiar do neurônio. A Figura 2.45 representa o modelo de um neurônio artificial genérico.




Figura 2.45 – Modelo de um neurônio artificial.

2.5.3 Funções de ativação

Em um neurônio, todos os sinais recebidos devem ser combinados para atingir o estado de ativação. O valor obtido da combinação de estímulos, obtido da Eq. 2.16, é chamado de entrada líquida. À entrada líquida, é aplicada a chamada função de ativação, acarretando a ativação propriamente dita do neurônio.

O grau de ativação de um neurônio não é necessariamente o mesmo de um segundo neurônio, mesmo que os dois recebam a mesma entrada líquida, pois existem diferenças de sensibilidade. Estas diferenças estão relacionadas com o limiar de ativação de cada neurônio. Este limiar provoca um deslocamento na função de ativação de modo a criar um aumento ou diminuição da sensibilidade do neurônio. O grau de ativação de um neurônio pode apresentar valores discretos, como é o caso dos valores de ativação binários (+1,-1), ou apresentar valores contínuos, restritos a um intervalo (0,+1).

A seguir serão apresentadas as funções de ativação mais importantes principalmente para os problemas relacionados aos processos de fabricação:

. Função Linear: função de ativação das mais simples (Eq. 2.17) e os valores para ativação são todos números reais. A Figura 2.46 representa graficamente este modelo de função de ativação.

$$f(x) = \alpha \cdot x \quad (2.17)$$

onde α representa o número real que define a saída linear para os valores de entrada, $f(x)$ é a saída e x é a entrada.




Figura 2.46 – Representação gráfica de uma função de ativação (linear).

. Função Rampa: é uma função linear (Eq. 2.18) que pode ser restringida para obter valores em uma faixa $[-\gamma, +\gamma]$, como mostrado na Fig. 2.47.

$$f(x) = \begin{cases} +\gamma & \text{se } x \geq +\gamma \\ x & \text{se } |x| < +\gamma \\ -\gamma & \text{se } x \leq -\gamma \end{cases} \quad (2.18)$$

Nesta função, os valores de máximo e mínimo são $+\gamma$ e $-\gamma$, respectivamente.




Figura 2.47 – Representação gráfica de uma função de ativação (rampa).

. Função Degrau: esta função produz uma saída $+\gamma$ para valores de x maiores que zero e $-\gamma$ para outros valores de x (Eq. 2.19). A Figura 2.48 reproduz graficamente a função de ativação degrau.

$$f(x) = \begin{cases} +\gamma & \text{se } x > 0 \\ -\gamma & \text{se } x \leq 0 \end{cases} \quad (2.19)$$




Figura 2.48 – Representação gráfica de uma função de ativação (degrau).

. Função Sigmoidal: é o tipo de função de ativação utilizada na maioria dos modelos de redes neurais existentes. Também conhecida como *S-shape*, confere grande capacidade de aprendizado devido a algumas características peculiares, tais como: ser uma função monotonamente crescente, de exibir suavidade, propriedades assintóticas, além de ser contínua e diferenciável em todo o seu domínio. Existem várias funções sigmoidais, porém uma das mais importantes e comumente usadas é a função logística (Eq. 2.20). A Figura 2.49 representa graficamente uma função de ativação sigmoidal logística.

$$f(x) = \frac{1}{1 + e^{-\frac{x}{T}}} \quad (2.20)$$

Onde o parâmetro T descreve a suavidade da curva.




Figura 2.49 – Representação gráfica de uma função de ativação (sigmoideal logística).

2.5.4 Arquiteturas das redes neurais

Quando se quer solucionar um problema via RNA, deve-se fornecer para a rede a maior quantidade possível de informações deste problema. Isto deve gerar a utilização de um grande número de nodos para realizar sub-tarefas específicas. Contudo, este procedimento acarreta grande esforço computacional, gerando a necessidade de se buscar uma definição correta do número de nodos e a quantidade de conexões entre eles. Para isto, deve-se realizar uma otimização do número de camadas e do número de nodos por camada na definição da arquitetura da RNA a ser utilizada (Braga et al., 1998).

A arquitetura de uma RNA consiste de um arranjo entre camadas, ou seja, de como os neurônios estão interconectados e organizados. As interconexões entre os neurônios são realizadas através de pesos (w). As camadas estão organizadas de forma que haja uma camada de entrada, uma ou mais camadas intermediárias ou ocultas e uma camada de saída.

A definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que esta arquitetura irá restringir qual o tipo de problema esta rede poderá tratar. Por exemplo, redes que possuem camada única de nodos só conseguem resolver problemas linearmente separáveis. Por sua vez, redes recorrentes são mais indicadas para resolver problemas que envolvem processamento temporal.

Para se definir a arquitetura de uma RNA, deve-se levar em conta os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre os nodos e a topologia da rede (Braga et al., 1998).

Arquitetura das redes quanto ao número de camadas:

- . Redes de camada única: só existe um nó entre qualquer entrada e qualquer saída da rede;
- . Redes de múltiplas camadas; existe mais de um neurônio entre alguma entrada e alguma saída da rede.

Arquitetura das redes quanto ao tipo de conexão dos nodos:

- . Redes unidirecionais *feed-forward*: a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada em camada de índice menor ou igual a i .
- . Redes recorrentes *feedback*: a saída de algum neurônio na i -ésima camada é usada como entrada de nodos em camadas de índice menor ou igual a i .

Quanto à conectividade, as redes neurais podem ser classificadas como: redes fracamente ou parcialmente conectadas e redes completamente conectadas.

2.5.5 Procedimento de aprendizado de uma rede neural

Uma RNA, para que se possa extrair a solução de uma tarefa, necessita de uma fase preliminar em que a ela é aplicado um aprendizado. Nesta fase, a rede irá extrair importantes informações de padrões que são apresentados. Com isto, a rede cria uma representação particular ao problema a ela apresentada.

O aprendizado consiste em um processo repetitivo de ajuste de parâmetros da rede, dos pesos das conexões entre as unidades de processamento. Ao final, estes parâmetros e pesos guardam o conhecimento que a rede adquiriu do processo em que ela está atuando.

Os principais métodos desenvolvidos para treinamento de rede são (Braga et al., 1998): o aprendizado supervisionado (e o aprendizado por reforço, que é um caso particular) e o aprendizado não-supervisionado (e o aprendizado por competição, que é um caso particular).

. Aprendizado supervisionado:

É chamado de aprendizado supervisionado porque as entradas e saídas da rede são fornecidas por um supervisor externo. Com isto, é possível ajustar os parâmetros de rede de maneira a encontrar uma relação entre os pares de entrada e saída que foram fornecidos.

O supervisor direciona o processo de treinamento fornecendo explicitamente o que é comportamento bom ou ruim para a rede. Então, a rede tem sua saída corrente comparada com a saída desejada e recebendo do supervisor, informação sobre o erro desta resposta.

Com o processo de comparação de padrões de entrada com a resposta desejada, ajusta-se os pesos das conexões para minimizar o erro. Esta minimização é incremental pois pequenos ajustes são feitos nos pesos para que estes convirjam para a solução. A soma de erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede.

Contudo, o aprendizado supervisionado apresenta a desvantagem de, se não houver supervisor, novas estratégias para situações desconhecidas ou não cobertas pela rede não serão possíveis de aprender.

O aprendizado por reforço é considerado, já que a rede tem um retorno do ambiente, como um caso particular do aprendizado supervisionado, diferindo-se pela medida de desempenho.

No aprendizado por reforço, o aprendizado recebe um *feed-back* do ambiente, que é apenas um sim ou não. Isto é apenas uma avaliação de desempenho da rede sem o fornecimento de informações de como melhorar o desempenho. Este aprendizado pode ser considerado um aprendizado com crítica ao invés de aprendizado com professor, pois ele não dá nenhuma sugestão de como pode ser a resposta correta.

Os paradigmas de aprendizagem por reforço podem ser:

- . Aprendizagem associativa: o meio fornece outras informações além do reforço e um mapeamento, na forma estímulo-ação que deve ser aprendido.

- . Aprendizagem não associativa: o sinal de reforço é a única entrada que o sistema recebe do meio. O sistema seleciona uma única ação ótima, ao invés de associar diferentes ações com diferentes estímulos.

- . Aprendizado não supervisionado:

Neste aprendizado não há professor ou supervisor. Para este tipo de algoritmo, somente os padrões de entrada estão disponíveis para a rede. A partir do momento que a rede estabelece uma coerência com as regularidades estatísticas de entrada de dados, desenvolve-se nela a capacidade de formar representações internas para codificar características de entrada e criar novas classes ou grupos automaticamente. Isto só será possível quando os dados de entrada possuírem redundância, pois do contrário não haveria possibilidade de encontrar padrões ou características dos dados de entrada.

Existem alguns métodos para implementação do aprendizado não supervisionado, dentre eles: Aprendizado Hebbiano, Modelo de Linsker, Regra de Oja, Regra de Yille além do Aprendizado por competição.

No aprendizado por competição, caso particular do aprendizado não supervisionado, as unidades de saída de um padrão de entrada disputam entre si para serem ativadas. Portanto, existe uma competição entre as unidades de saída para saber qual delas terá sua saída ativada e seus pesos atualizados.

Por isso, as unidades que tiverem maior ativação inicial terão maior chance de vencer a disputa das outras unidades, que perderão o poder de inibição ao longo do tempo com relação à unidade de maior ativação.

2.5.6 Método *Backpropagation*

O método de treinamento *backpropagation* para redes neurais nasceu da necessidade de solucionar o fraco desempenho proporcionado pelas redes lineares, como uma alternativa às situações onde uma regressão linear era insuficiente para relacionar padrões de entrada aos padrões de saída.

. Redes *perceptron* multi-camadas (MLP)

Redes do tipo *perceptron* multi-camadas ou *multilayer perceptron* (MLP) apresentam um poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias ou escondidas. Estas podem tratar dados que não são linearmente separáveis. Teoricamente, redes com duas camadas intermediárias podem implementar qualquer função, seja esta do tipo linearmente separável ou não. Sua precisão e a implementação da função objetivo depende do número de nodos utilizados nas camadas intermediária.

Entende-se que as unidades intermediárias de uma MLP funcionam como detectores de características. Elas geram uma codificação interna dos padrões de entrada, que é então utilizada para a definição da saída da rede. Obtendo-se um número suficiente de unidades intermediárias, é possível formar representações internas para qualquer conjunto de padrões de entrada necessárias para implementar uma RNA (Braga et al., 1998):

- Uma camada intermediária é suficiente para aproximar qualquer função contínua.
- Duas camadas intermediárias são suficientes para aproximar qualquer função matemática.

O número adequado de nodos depende de vários fatores e geralmente é realizado empiricamente. Porém, alguns métodos tem sido empregados e devem levar em consideração os seguintes aspectos:

- Número de exemplos de treinamento;
- Quantidade de ruído presente nos exemplos;
- Complexidade da função a ser aprendida;
- Distribuição estatística dos dados de treinamento.

. Algoritmo *backpropagation*

O algoritmo *backpropagation* é empregado no aprendizado das redes MLP, sendo que a maioria das RNA's deste tipo utiliza alguma de suas variações. O *back-propagation* é um algoritmo de aprendizado estático, isto é, não altera a estrutura da rede, apenas variando os valores de seus pesos, diferentemente dos algoritmos dinâmicos, que podem alterar (aumentando ou diminuindo o número de nodos, camadas intermediárias e conexões) o

tamanho da rede. Além disso, este algoritmo utiliza pares de entrada e saída desejado para ajustar os pesos da rede, através de um mecanismo de correção de erros.

O treinamento ocorre em duas fases: a fase *forward* define a saída da rede para um dado padrão de entrada; a fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A seguir, um esquema de como funciona o algoritmo *back-propagation*:

- . Inicializar pesos e parâmetros
- . Repetir até o erro ser mínimo ou a realização de um dado número de ciclos:
 - . Para cada padrão de entrada X
 - . Definir saída da rede através da fase *forward*;
 - . Comparar saídas produzidas com as saídas desejadas;
 - . Atualizar pesos dos nodos através da fase *backward*.

Descreve-se matematicamente as fórmulas empregadas pelo algoritmo *backpropagation* para atualização dos pesos de uma rede MLP. A Equação 2.21 define o erro a ser minimizado:

$$E = \frac{1}{2} \sum (t_m - u_m)^2 \quad (2.21)$$

Onde E é o sinal de erro entre os valores reais desejados t_m , relativos ao padrão de entrada x_i , e as respostas estimadas pela rede u_m , dada na camada de saída.

Para cada neurônio “m” na camada de saída, e cada neurônio “k” na camada intermediária, os erros δ_m e δ_k , respectivamente, são dados pelas Eqs. 2.22 e 2.23:

$$\delta_m = u_m (1 - u_m) \cdot (t_m - u_m) \quad (2.22)$$

$$\delta_k = h_k (1 - h_k) \cdot \sum (\delta_m W_{km}) \quad (2.23)$$

Portanto, as mudanças incrementais nos pesos relativos à n-ésima interação ($\Delta w(n)$) entre a m-ésima unidade da camada de saída e a k-ésima unidade da camada oculta, e entre a k-ésima unidade da camada oculta e a j-ésima unidade da camada de entrada, podendo ser definidas pelas Eqs 2.24 e 2.25:

$$\Delta W_{km}(n) = \eta \delta_m h_k + \alpha \Delta W_{km}(n-1) \quad (2.24)$$

$$\Delta W_{jk} = \eta \delta_k x_j + \alpha \Delta W_{jk}(n-1) \quad (2.25)$$

Onde η é a taxa de aprendizagem e α é o fator de amortecimento momentum, que tem a função de diminuir mudanças mais bruscas no espaço dos pesos.

2.5.7 Rede Neural Probabilística (PNN)

Dentre os vários modelos de redes neurais artificiais existentes, a Rede Neural Probabilística ou *Probabilistic Neural Network* (PNN) foi o modelo escolhido neste trabalho. Os motivos de sua escolha serão apresentadas a seguir em uma breve descrição de sua história e características gerais.

O algoritmo padrão para as Redes PNN foi baseado na teoria dos Classificadores Bayesianos (desenvolvido nos anos 50) e descrito por Meisel em 1972. Este algoritmo leva em consideração a probabilidade relativa dos eventos ocorridos e usa esta informação para predição. As PNN também utilizam os conceitos de Estimadores Parzen, que foram desenvolvidos para construir as funções densidade de probabilidade requeridas pela teoria Bayesiana (Master, 1993).

Apesar de ser uma ferramenta extremamente poderosa, o algoritmo permaneceu no esquecimento em função das exigências de elevado processamento computacional. Entretanto, Specht (1990) mostrou que o algoritmo poderia ser implementado na forma de rede neural, bastando para isso, que fosse dividido em vários componentes individuais (neurônios ou processadores) para operação em paralelo. É esta capacidade de operação em paralelo que permite a associação do algoritmo de Meisel (1972) à uma rede neural, pois a grosso modo, as PNN operam segundo conceitos consolidados da estatística tradicional (Master, 1993).

A PNN é intrinsecamente um algoritmo projetado para executar tarefas de classificação, sendo treinada para avaliar amostras desconhecidas e associá-las com uma determinada classe do conjunto de treinamento.

A classificação de padrões consiste basicamente na alocação de eventos a grupos, ou classes, pré-identificados, com características similares. A classificação é efetuada utilizando como base toda a informação disponível sobre o fenômeno analisado, proveniente de sua classificação. A utilização de um maior número de parâmetros de caracterização aumenta a capacidade discriminatória entre os eventos pelo aumento da dimensão dos dados de análise (Fernandes; Alves; Junior, 2005). Então, a partir de um classificador de padrões, cada evento é avaliado e passa a pertencer a uma determinada classe.

As redes neurais diretas com múltiplas camadas também são excelentes classificadoras. De qualquer forma, apresentam dois problemas: o primeiro é o desconhecimento da forma de operação e o comportamento esperado do mesmo. O segundo e mais sério, é a velocidade de treinamento da rede, a qual pode ser extremamente baixa. Por outro lado, as PNN têm um modelamento matemático consolidado, são treinadas rapidamente e classificam significativamente bem, comparadas com as redes diretas de múltiplas camadas (Master, 1993).

As principais desvantagens das redes probabilísticas são a relativa lentidão para classificar e a exigência de grande quantidade de memória computacional. No entanto, como foi mencionado anteriormente, uma PNN pode ser implementada através de vários processadores, facilitando a implementação da máquina.

Na Figura 2.50 são apresentadas duas classes ($\clubsuit$, $\diamond$), onde a coordenada do eixo das abscissas de um elemento qualquer de uma das classes é definida por uma variável, ao passo que a coordenada do eixo das ordenadas é definida por outra variável. Se uma amostra desconhecida (?), como observado na figura, for apresentada a um classificador que avalia apenas tendências centrais, a mesma será classificada como ($\diamond$), enquanto que esta amostra pertence verdadeiramente à classe dos ($\clubsuit$).




Figura 2.50 - Exemplo de um problema de classificação: tendências centrais (Meola, 2005).

Um método que calcula a distância entre a amostra desconhecida e todos os membros do conjunto de treinamento, chamado comumente de “classificador do vizinho mais próximo”, terá desempenho satisfatório num caso como este, entretanto, falha numa situação como a ilustrada na Fig. 2.51. Nesta, verifica-se que a amostra desconhecida (?) pertence à classe dos ($\clubsuit$), a despeito de estar mais próxima de um membro da classe dos ($\diamond$).




Figura 2.51 - Exemplo de um problema de classificação: vizinho mais próximo (Meola, 2005).

. Método de Classificação de Bayes

A rede neural probabilística tem como base o método estatístico de Bayes, o qual será detalhado a seguir.

Considerando-se uma coleção de amostras aleatórias de K populações, onde cada amostra, indexada de $k=1, 2, \dots, K$, é um vetor $x=[x_1, x_2, \dots, x_m]$. Num caso geral, admite-se que tais amostras tenham diferentes probabilidades, denominadas h_k . Quando um erro de classificação é cometido com um caso que certamente pertence à população k , o custo associado com este erro é c_k , entretanto, em muitos casos, segundo (Master, 1993), as probabilidades h_k são admitidas iguais para todas as amostras, e o mesmo é feito para o custo c_k .

A coleção completa é chamada de conjunto de treinamento, contendo n_1 amostras da classe 1, n_2 da classe 2 e n_k da classe k . Um algoritmo apto a associar corretamente uma amostra desconhecida à uma das classes do conjunto de treinamento, deve ser gerado a partir desse procedimento. O algoritmo taxado como um Bayes ótimo ocorre para o caso em que o mesmo tenha um custo de erro de classificação maior do que qualquer outro.

Prova-se que haverá uma regra de decisão de Bayes ótima caso seja fornecida a verdadeira função densidade de probabilidade (fdp) para toda a coleção de amostras. Faz-se a classificação de uma amostra desconhecida X como pertencente à uma classe i , como mostrado na Eq. 2.26, se:

$$h_i c_i f_i(X) > h_j c_j f_j(X) \quad (2.26)$$

para toda amostra $j \neq i$.

$f_k(X)$ trata-se da concentração (densidade) de membros da classe k ao redor da amostra desconhecida. De acordo com a regra de Bayes, deve-se favorecer a classe que possui maior

densidade de membros na vizinhança da amostra desconhecida. Há, no entanto, um problema da regra de Bayes, em que não se conhece a verdadeira fdp $f_k(X)$. Neste caso, deve-se utilizar uma estimativa para a fdp. Parzen (1962), apresenta um excelente estimador para a fdp unidimensional que converge para a verdadeira fdp quando o número de amostras cresce.

. Método de Estimativa da fdp

O estimador da fdp de Parzen utiliza uma função de ponderação $W(d)$, conhecida como função Kernel, a qual possui os maiores valores para $d = 0$ e, decresce rapidamente com o valor absoluto de d . Um Kernel é centrado em cada ponto da amostra, com o valor de cada uma dessas funções, em uma coordenada x , determinado pela distância d entre x e o ponto da amostra. O estimador da função densidade de probabilidade da amostra é a soma escalonada destas funções para todos os casos da amostra.

Dada uma amostra de uma variável aleatória unidimensional de tamanho (n) , a sua fdp pode ser estimada segundo a Eq. 2.27:

$$g(x) = \frac{1}{n\sigma} \sum_{i=1}^n W\left(\frac{x - x_i}{\sigma}\right) \quad (2.27)$$

Onde σ é o parâmetro de escala que define a largura da curva sino centrada em cada membro da coleção de dados.

Para uma valor muito pequeno de σ , o estimador tende a valorizar os pontos amostrais demasiadamente, e para valores muito grandes, o estimador despreza quase que completamente a influência dos pontos amostrais vizinhos.

As propriedades impostas para as funções candidatas à janela Kernel foram estabelecidas por Parzen (1962) e Specht (1990), como segue:

- A função deve ser limitada e é dada pela Eq. 2.28

$$\max_x |W(x)| < \infty \quad (2.28)$$

- A magnitude de função de ponderação deve tender a zero à medida que o módulo do seu argumento aumenta. Tal restrição é representada pelas Eqs. 2.29 e 2.30:

$$\int_{-\infty}^{\infty} |W(x)| dx < \infty \quad (2.29)$$

$$\lim_{x \rightarrow \infty} |W(x)| dx = 0 \quad (2.30)$$

- A função de ponderação deve ser apropriadamente normalizada, atendendo à Eq. 2.31:

$$\int_{-\infty}^{\infty} W(x) dx = 1 \quad (2.31)$$

- A função de ponderação deve estreitar-se com o aumento do tamanho amostral, com intuito de se obter um comportamento assintótico. As Equações 2.32 e 2.33 representam ambas as condições que devem ser satisfeitas para o parâmetro de escala em função de n.

$$\lim_{x \rightarrow \infty} \sigma_n = 0 \quad (2.32)$$

$$\lim_{x \rightarrow \infty} n\sigma_n = \infty \quad (2.33)$$

A $W(d)$ muitas vezes emprega a função Gaussiana, devido não à sua normalidade, mas ao fato de satisfazer as exigências do método Parzen, apresentar as conveniências matemáticas de ter bom comportamento e possuir facilidade no cálculo.

. Arquitetura e Funcionalidade da Rede Neural Probabilística

Numa rede treinada para executar tarefas de classificação, o número de entradas é exatamente igual ao número de parâmetros necessários para identificar uma determinada classe. A camada de entrada é fictícia, uma vez que seus neurônios não executam nenhuma operação. A camada de classificação é constituída de um neurônio para cada caso do conjunto de treinamento. O processo de classificação inicia com a apresentação da amostra desconhecida para todos os neurônios da camada de classificação. Cada neurônio de classificação calcula a distância medida entre a amostra de entrada e o caso do conjunto de treinamento ao qual ele está associado. Esta distância será o argumento da função de ativação do neurônio, que é necessariamente uma janela Parzen. Cada neurônio da camada de somatório simplesmente soma a saída dos neurônios da camada de classificação correspondente à sua classe. O nível de ativação do neurônio somador k é o valor da fdp estimada da população k . O neurônio da camada de saída é um classificador simples, que decide qual das entradas provenientes da camada de somatório possui o valor máximo.

. Rede Neural Probabilística aplicada na usinagem

Li et al. (2003) empregou uma PNN no diagnóstico do estado da ferramenta no processo de rosqueamento, além de outros aspectos típicos deste processo. O sinal empregado foi a corrente retirada diretamente do motor do eixo árvore. Após a aquisição do sinal, os autores aplicaram procedimentos matemáticos com a finalidade de primeiro, extrair características relevantes aos objetos de estudo do trabalho e, posteriormente, reduzir a dimensão e eliminar correlação entre as características selecionadas no primeiro estágio. Com os resultados desta primeira etapa, foi treinada uma PNN. As classes resultantes como resposta esperada pela PNN e seus respectivos sucessos são apresentadas na Tab. 2.3:

Tabela 2.3: Taxa de sucesso na classificação dos dados.

Classes:	Ferramenta Normal	Gasta	Furo Desalinhado	Furo Pequeno	Furo Grande	Média
Sucesso:	100%	100%	84,6%	86,7%	92,3%	93,1%

A Figura 2.52 descreve graficamente o sucesso na classificação da PNN. A classe 1 representa o macho de corte no estado normal, a classe 2 representa o centro do furo desalinhado em relação ao centro do macho de corte, a 3 um furo grande, a 4 um furo pequeno e a 5 uma ferramenta gasta. Observa-se que duas amostras que representariam a classe 2 foram classificadas nas classes 3 e 4. Da mesma maneira, uma amostra da classe 3 e outra da classe 4 foram classificadas como classe 2. Os autores acreditam que a razão do relativo insucesso da classe 2 (desalinhamento furo com o macho) é devido a baixa sensibilidade do sinal de corrente às forças laterais relativamente altas que aparecem quando ocorre o desalinhamento.

Axinte (2005) desenvolveu uma metodologia de detecção e classificação do mal funcionamento de uma ferramenta de brochamento. O sinal adquirido foi de força e o autor usinou ligas de níquel de aplicação aeroespacial. O sinal foi analisado no domínio do tempo e um programa desenvolvido por sua equipe extraiu suas características mais relevantes. Em seguida, uma PNN foi empregada para a classificação da ferramenta em 2 situações diferentes de desgaste: dente da brocha bom e dente gasto.




Figura 2.52 – Resultados da classificação da PNN (Li et al., 2003).

A Figura 2.53 representa graficamente os resultados obtidos pela PNN empregada neste trabalho. Nesta figura, a partir de certos valores de força, a PNN deveria classificar a condição do dente da ferramenta como gasta. Segundo o autor, a taxa média de sucesso de sua classificação foi de 92%.




Figura 2.53 – Resultados da classificação da PNN (Axinte, 2005).

Capítulo III

Metodologia

Este capítulo tem como objetivo descrever os procedimentos experimentais adotados neste trabalho. A partir destes experimentos, obtiveram-se os resultados que serviram de base para a execução de análises e discussões a respeito do monitoramento da evolução do desgaste de flanco máximo ($VB_{Bmáx}$) e até uma eventual falha em uma ferramenta durante o processo de fresamento, utilizando sinais de emissão acústica.

O trabalho foi realizado em três partes. Na primeira parte foram realizados ensaios para a verificação da possibilidade do emprego do sinal RMS de emissão acústica (EA_{RMS}) no fresamento. Para isto, foram usadas diferentes quantidades de insertos na ferramenta e um mapa de intensidade luminosa montado a partir do sinal de EA. Na segunda parte deste trabalho foi utilizado o sinal bruto de emissão acústica e também foi avaliada uma metodologia para utilizá-la no monitoramento da condição de desgaste da ferramenta no fresamento. A primeira e segunda partes integram o objetivo central do trabalho. A terceira parte foi realizada no torneamento e utilizado o sinal RMS da emissão acústica. Foi analisada a correlação entre o sinal de emissão acústica e a rugosidade da superfície usinada para diferentes estágios de desgaste. Esta parte é considerada uma etapa paralela ao trabalho e é apresentada em Anexo único.

3.1 Testes com o Sinal RMS da Emissão Acústica

Os testes foram realizados com o objetivo de facilitar a compreensão de como o mapa de intensidade luminosa montado através do sinal RMS de emissão acústica comporta-se quando os insertos de uma fresa apresentam diferentes estados de desgastes. Foram empregadas algumas combinações do número de insertos (2, 4 e 8, que é o limite da fresa). Também foram realizados testes para verificação do potencial do mapa de intensidade luminosa em outras aplicações no fresamento, tais como: batimento radial e axial, formação de rebarba, reprodução visual do corte em condições normais e com mudança de direção de avanço.

3.1.1 Materiais dos corpos de prova

Os experimentos desta tese consistiram basicamente no fresamento frontal de barras de aço microligados perlíticos de forja (DIN 38MnS6) otimizados com dimensões de 400x50 mm e altura de 100 mm, fornecidos pela Aços Villares e cuja composição química é mostrada na Tab. 3.1.

Tabela 3.1 – Composição química do aço microligado perlítico de forja DIN 38MnS6.

Composição	Din 38MnS6 (% peso)
C	0,3800
Mn	1,5000
P	0,0240
S	0,0610
Si	0,5400
Ni	0,0600
Cr	0,1800
Mo	0,0300
V	0,0040
Al	0,0060
Cu	0,1500
Pb	0,0020
Ti	0,0017
Nb	0,0050
B	0,0007
Sn	0,0070
Ca	0,0005
H2	0,0002
N2	0,0159
Te	0,0027

A microestrutura deste aço microligado é predominantemente perlítica, como pode ser observado na Fig. 3.1




Figura 3.1 – Microestrutura do aço microligado perlítico de forja Din 38MnS6 otimizado. a) região central, b) região periférica.

A dureza dos materiais usinados foi medida sobre duas amostras, sendo cada uma retirada de barras diferentes. As amostras para medição de dureza possuíam as dimensões de 12x15x100 mm. Para monitoramento da variação da dureza ao longo da seção das duas amostras, tomou-se: o ponto central da amostra (ponto 0), 7 pontos acima com espaçamento aproximado de 6,5 mm entre eles e os 7 pontos simétricos abaixo. A Figura 3.2 ilustra a região do corpo de prova de onde foi retirada a amostra e os seus respectivos pontos para avaliação da dureza do aço. Na região de cada ponto da amostra, e para cada uma das amostras analisadas, foi medida a dureza Vickers duas vezes, com um durômetro universal da marca Wolpert sob uma carga de 20 Kg e tempo de permanência de 40 s. Para o cálculo da dureza ao longo da seção dos materiais, tomou-se a média dos valores da dureza obtidos para a região central e a média dos pontos simétricos, para as duas amostras. A Tabela 3.2 traz a dureza média do ponto central e dos pontos periféricos simétricos para o aço empregado como corpo de prova neste trabalho.

Também foram utilizados outros metais ao longo dos ensaios. O sinal de emissão acústica foi monitorado durante o fresamento de um bloco de motor. Este ensaio teve por finalidade a visualização do corte através de um mapa de intensidade luminosa obtido a partir deste sinal. Os blocos foram fornecidos pela TEKSID, do grupo Fiat. É fabricado segundo norma UNI – Ferro Fundido Cinzento Lamelar GH190 e possui as seguintes características (fornecidas pelo fabricante):

- . Dureza Brinell – $D_R = 190$ a 240 HB;
- . Tensão de ruptura (mínima) - $\tau_R = 255$ N/mm²;
- . Módulo de elasticidade – $E = 117700$ N/mm².

Os resultados desta etapa podem ser vistos no capítulo IV.

No torneamento, foi empregada uma barra de aço ABNT 1045. Maiores detalhes desta etapa do trabalho pode ser visto no Anexo.




Figura 3.2 – Amostra para obtenção da dureza do aço usinado Din 38MnS6 e os respectivos pontos de medição da dureza.

Tabela 3.2 – Variação da dureza Vickers do aço microligado perlítico de forja ao longo da seção transversal.

Material	0 (centro)	1	2	3	4	5	6	7 (periferia)	Média	Desvio Padrão	Nº de dados
Din											
38MnS6 (otimizado)	258	254	256	256	258	264	256	260	258	3,1	8

3.1.2 Condições de corte e especificações da ferramenta

A operação de fresamento consistiu na usinagem da peça ao longo de toda sua maior dimensão, como pode ser visto no esquema apresentado na Fig. 3.3. Este procedimento foi adotado para todos os ensaios com o sinal bruto de emissão acústica e para algumas situações em que este sinal foi adquirido com o filtro RMS.




Figura 3.3 – Esquema do fresamento frontal e dimensões da peça empregados neste trabalho.

Alguns ensaios com mudança de direção de avanço também foram realizados. Esta mudança de direção foi realizada com o objetivo de avaliar como este procedimento se reproduziria no mapa. Nestes ensaios, a ferramenta entra pela lateral, no início da peça, depois a percorre longitudinalmente (Figs. 3.4a e b). O *trigger* e o espelho refletor do laser foram ajustados para que não houvesse a mudança de coluna na construção do mapa enquanto um dos insertos estivesse na fase ativa da primeira direção de avanço. Como o *trigger* estava montado no cabeçote do centro de usinagem, acompanhando os movimentos da fresa, o ajuste anterior faz com que haja uma interrupção na representação gráfica da fase ativa de um dos insertos quando ocorre a mudança de direção. Foram utilizados dois insertos em uma barra com 100 mm de largura, contra 50 mm dos outros ensaios. Aqui foi adquirido apenas o RMS do sinal de emissão acústica.

As operações de fresamento foram realizadas em um centro de usinagem CNC Romi *Discovery* 760, que possui potência máxima de 11 kW (15 cv), variação contínua de velocidade de corte e avanço, capacidade máxima de rotação do eixo árvore de 10.000 rpm e avanço rápido de até 25.000 mm/min. A fresa utilizada é uma R245 125Q40-12M de 125 mm de diâmetro, fabricada pela *Sandvik Coromant*, em que podem ser instalados até oito insertos. Os insertos de metal duro empregados têm especificação R245-12 T3 M-PM 4030, classe P, também fabricados pela *Sandvik Coromant*, possuem quatro arestas de corte e quatro arestas alisadoras e são revestidas com nitreto de titânio (TiN).




Figura 3.4 – (a) Direção de avanço inicial do fresamento; (b) Direção de avanço final do fresamento.

As condições de corte empregadas nos experimentos são mostrados na Tab. 3.3:

Tabela 3.3 – Condições de corte empregadas para os testes.

teste	V_c (m/min)	a_p (mm)	f_z (mm/volta)
1 (desbaste)	205	1,5	0,24
2 (intermediária)	250	1,0	0,20
3 (acabamento)	300	0,5	0,16

Estas condições foram escolhidas com a finalidade de se criar condições extremas de usinagem. Portanto, uma condição mais severa, que é a de desbaste, uma bem mais suave, que é uma condição de acabamento e uma terceira, intermediária, criada com intuito de se obter um campo mais abrangente de resultados.