

ESTE EXEMPLAR CORRESPONDE A REDAÇÃO FINAL DA
TESE DEFENDIDA POR CELSO MINORU HARA
E APROVADA PELA
COMISSÃO JULGADORA EM 06/07/95

Imp.
Set./95

Anselmo Eduardo Diniz
ORIENTADOR

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
DEPARTAMENTO DE ENGENHARIA DE FABRICAÇÃO

^{nt}
Utilização de Redes Neurais
na Análise de Sinais de Vibração
de Ferramenta de Torneamento

Autor: Celso Minoru Hara^{nt}

Orientador: Anselmo Eduardo Diniz^t

Curso: Engenharia Mecânica.

Área de Concentração: Materiais e Processos de Fabricação

Dissertação de mestrado apresentado à comissão de
Pós Graduação da Faculdade de Engenharia Mecânica, como
requisito para a obtenção do título de Mestre em Engenharia
Mecânica.

Campinas, 1995

S.P. - Brasil



00076719-9

ADDE	BC
INSTITUIÇÃO:	
T/UNICAMP	
H 212 u	
25507	
433/95	
☐ D ☒	
8411,00	
19/09/95	
CPD	

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

H212u Hara, Celso Minoru
Utilização de redes neurais na análise de sinais de
vibração de ferramenta de torneamento / Celso Minoru
Hara.--Campinas, SP: [s.n.], 1995.

Orientador: Anselmo Eduardo Diniz.
Dissertação (mestrado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Mecânica.

1. Redes neurais (Computação). 2. Máquinas -
Monitoração. I. Diniz, Anselmo Eduardo.
II. Universidade Estadual de Campinas. Faculdade de
Engenharia Mecânica. III. Título.

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA


TESE DE MESTRADO

TÍTULO DA TESE: "UTILIZAÇÃO DE REDES NEURAIS NA
ANÁLISE DE SINAIS DE VIBRAÇÃO DE FERRAMENTA DE
TORNEAMENTO"


AUTOR: CELSO MINORU HARA

ORIENTADOR: PROF. DR. ANSELMO EDUARDO DINIZ


APROVADO POR:



PROF. DR. ANSELMO EDUARDO DINIZ, PRESIDENTE



PROF. DR. PAULO CORREA LIMA



PROF. DR. REGINALDO TEIXEIRA COELHO

CAMPINAS, 02 DE JUNHO DE 1995

AGRADECIMENTOS

Quero deixar meus sinceros agradecimentos:

Ao meu orientador Prof. Dr. Anselmo Diniz pela atenção e disposição em ajudar durante todo o período de execução do trabalho e por tudo o que me foi possibilitado aprender durante o mesmo;

Aos meus pais, Roberto e Neide, pelo carinho com que me criaram e pelo incentivo que me deram, dando-me coragem para superar todos os obstáculos;

À CAPES , pelo apoio financeiro;

Ao técnico Ari pela solicitude e prestatividade quando da execução dos ensaios;

Aos pós-graduandos Marcão, Tavares e Rubinho pela valorosa contribuição prestada;

E aos amigos do DEF e do DEMA que contribuíram direta ou indiretamente para a consecução dos objetivos deste trabalho.

RESUMO

O objetivo principal deste trabalho é mostrar a eficácia da utilização de redes neurais em sistemas de monitoramento da vida da ferramenta usando sinais de vibração. Para tal, montou-se um sistema composto de acelerômetros piezoelétricos adaptados ao porta-ferramentas, acopladores que podem ler o sinal fornecido pelos acelerômetros e uma placa analógica/digital que converte esses sinais de maneira que possam ser armazenados e lidos pelo computador.

Realizou-se ensaios de torneamento cilíndrico variando-se as condições de usinagem (velocidade de corte e avanço) em aço ABNT 4340. O sinal de vibração foi adquirido e armazenado e as rugosidades média e máxima da superfície da peça foram medidas. Posteriormente, executou-se uma rede neural "back-propagation" tendo como valores de entrada os sinais de vibração e as condições de usinagem e fornecendo como saída a indicação do estado de desgaste da ferramenta.

A contribuição mais importante deste trabalho é a indicação através da rede neural, de um intervalo de melhor aproveitamento da ferramenta de corte no que se refere ao desgaste, possibilitando utilizá-la da melhor forma até o momento de sua troca.

ABSTRACT

The main goal of this work is to show the feasibility of employing neural networks techniques on tool life monitoring systems using vibration signals. For this purpose, a system was set with two piezoelectrical accelerometers attached on the tool holder, couplers that can read the signal emitted by the accelerometers and an A/D board that converts these signals in order to save and read them in the computer.

Several turning tests were carried out with different cutting conditions using ABNT 4340 steel as the workpiece material. The vibration signals were sampled and stored and the average and maximum surface roughness of the workpiece were measured. Later, a back-propagation neural network was run with cutting conditions and vibration signals as input parameters and with tool wear status as output parameter.

The most important conclusion of this work is that the neural network is able of establishing an interval of cutting time where the tool must be replaced, optimizing the utilization of the tool.

LISTA DE SÍMBOLOS E SIGLAS UTILIZADOS

AC	corrente alternada
A/D	analógico/digital
A_p	profundidade de usinagem
b	largura de corte [mm]
DC	corrente contínua
E.A.	emissão acústica
f	avanço [mm/volta]
F_c	força principal de corte
FFT	transformada rápida de Fourier
h	espessura de corte [mm]
I	intensidade de corrente elétrica
K_s	pressão específica de corte
PSD	densidade de potência espectral
R	resistência elétrica
RMS	raiz quadrada da média
R_a	rugosidade média [μm]
$R_{\text{máx}}$	rugosidade máxima [μm]
V_c	velocidade de corte [m/min]
W	peso da conexão da rede neural
X	valor de entrada do elemento processador da rede neural
Y	valor de saída do elemento processador da rede neural

ÍNDICE

1. INTRODUÇÃO.....	1
2. MONITORAMENTO DO PROCESSO DE USINAGEM.....	4
2.1. INTRODUÇÃO.....	4
2.2. MONITORAMENTO DO PROCESSO DE USINAGEM...5	
2.3. MÉTODOS DIRETOS DE MONITORAMENTO.....	7
2.4. MÉTODOS INDIRETOS DE MONITORAMENTO.....	8
2.4.1. MÉTODO DE MONITORAMENTO INDIRETO POR ESFORÇOS DE CORTE.....	8
2.4.1.1. RELAÇÃO ENTRE FORÇA DE CORTE NA USINAGEM E O DESGASTE DA FERRAMENTA.....	10
2.4.1.2. RELAÇÃO ENTRE ESFORÇOS DE CORTE E CONDIÇÕES DE USINAGEM	11
2.4.1.3. ESFORÇOS DE CORTE E QUEBRA DA FERRAMENTA.....	13
2.4.2. MONITORAMENTO DOS ESFORÇOS DE CORTE VIA PARÂMETROS ELÉTRICOS.....	14
2.4.3. MONITORAMENTO INDIRETO VIA E. A.....	16
2.4.3.1. INFLUÊNCIA DAS CONDIÇÕES DE USINAGEM E DA GEOMETRIA DA FERRAMENTA NOS VALORES DE E. A.	20
2.4.3.2. MONITORAMENTO DO DESGASTE E QUEBRA DA FERRAMENTA VIA E. A.	21

2.4.4. MONITORAMENTO INDIRETO DA USINAGEM VIA VIBRAÇÕES.....	23
2.4.4.1. INFLUÊNCIA DAS CONDIÇÕES DE USINAGEM NA ESTABILIDADE DO SISTEMA.....	25
2.4.4.2. MONTAGEM E INSTRUMENTAÇÃO.....	26
2.4.4.3. ANÁLISE DO SINAL E ESTRATÉGIA DE MONITORAMENTO VIA VIBRAÇÃO.....	28
3. REDES NEURAIS.....	33
3.1. INTRODUÇÃO - O QUE É COMPUTAÇÃO NEURAL.....	33
3.2. ANALOGIA COM O CÉREBRO.....	34
3.3. CONSTITUIÇÃO DAS REDES NEURAIS.....	39
3.3.1. OS ELEMENTOS PROCESSADORES.....	39
3.3.2. A TOPOLOGIA.....	39
3.3.3. AS REGRAS DE APRENDIZADO.....	40
3.4. LINHA EVOLUTIVA DA NEUROCOMPUTAÇÃO.....	42
3.5. REDES NEURAIS EM “BACK-PROPAGATION”.....	51
3.5.1. TOPOLOGIA DA REDE “BACK-PROPAGATION”.....	52
3.5.2. REGRA DE APRENDIZADO NA REDE “BACK-PROPAGATION”.....	53
3.6. APLICAÇÕES DE REDES NEURAIS.....	56
3.6.1. EXEMPLOS DE APLICAÇÕES DE REDES NEURAIS NA USINAGEM.....	58
4. EQUIPAMENTOS, MATERIAIS E PROCEDIMENTOS EXPERIMENTAIS.....	63
4.1. EQUIPAMENTOS UTILIZADOS E MONTAGEM DO SISTEMA.....	63
4.2. MATERIAL USINADO.....	68

4.3. METODOLOGIA DOS ENSAIOS DE USINAGEM.....	69
4.4. EXECUÇÃO DAS REDES NEURAIS.....	72
5. RESULTADOS E DISCUSSÕES.....	76
5.1. ENSAIO DE VIDA DA FERRAMENTA VARIANDO-SE AS CONDIÇÕES DE USINAGEM.....	76
5.2. TREINAMENTO DA REDE NEURAL “BACK- PROPAGATION A PARTIR DE PARÂMETROS DO ENSAIO DE USINAGEM.....	89
6. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	101
BIBLIOGRAFIA.....	104

CAPÍTULO 1

INTRODUÇÃO

A inteligência artificial vem sendo objeto de crescente atenção por parte de pesquisadores, sendo que nas décadas recentes (mormente a partir dos anos 60), suas aplicações têm sido expandidas a áreas diversas, multidisciplinares. Muitas dessas aplicações saem dos ambientes meramente acadêmicos, encontrando emprego no escopo da vida real, seja em ambientes industriais, hospitais ou instituições de pesquisa, bem como em previsão do tempo, a custos bastante acessíveis e com vantagens diversas, como racionalização de recursos materiais e humanos e sobretudo, de tempo.

Definindo de modo simplista, a inteligência artificial procura dotar o computador com habilidades e atributos tipicamente humanos, constituindo-se as redes neurais em uma das mais poderosas ferramentas desse campo emergente.

As redes neurais são baseadas em expressões e formulações matemáticas na forma de algoritmos que simulam o funcionamento do cérebro humano, baseado este em evidência neuronal. Ou seja, as redes neurais simulam emaranhados de neurônios e seu processamento imita o quanto possível o comportamento biológico e funcional dos tecidos que formam o cérebro humano.

É a partir dessa imitação do comportamento humano, aliada às tecnologias resultantes do avanço da informática, que advêm muitas vantagens desses sistemas, além daquelas citadas

anteriormente, além de permitir restringir a interferência do homem a atividades cuja presença física e ação humanas sejam realmente imprescindíveis.

Numerosas aplicações de redes neurais no processo de usinagem dos metais têm sido relatadas por cientistas e pesquisadores, algumas das quais, devido à sua relevância ou carga didática serão sumariamente relatadas em capítulo posterior.

Dentro da usinagem dos materiais, a aplicação de redes neurais em sistemas de monitoramento do desgaste e fim de vida das ferramentas de corte tem tido atenção recente e alguns resultados entusiasmadores têm vindo à tona.

É na aplicação de redes neurais sobre um dos métodos de monitoramento, no caso via vibrações do sistema máquina-ferramenta-dispositivo de fixação-peça, que se enfoca o presente trabalho, onde se pretende expor a viabilidade do uso desse instrumento da inteligência artificial em favor de uma otimização dos processos de monitoramento e controle, bem como propiciar sugestões para futuros trabalhos nessa área.

Para tanto, essa dissertação é dividida em seis capítulos, cuja breve descrição se segue conforme:

Capítulo 1 - Introdução :

Uma visão sucinta sobre o conteúdo da dissertação e suas propostas.

Capítulo 2 - Monitoramento do Processo de Usinagem

Relata alguns dos principais métodos de monitoramento, dando um sumário de suas faixas de aplicação, vantagens, desvantagens, com ênfase no método via vibrações, adotado nos ensaios desta obra.

Capítulo 3 - Redes Neurais :

Explica o que são as redes neurais, como elas funcionam, suas características relevantes, um breve histórico da neurocomputação, a rede back-propagation e algumas das aplicações das redes neurais.

Capítulo 4 - Equipamentos, Materiais e Procedimentos Experimentais:

Versa sobre os materiais, equipamentos, procedimentos e critérios adotados nos ensaios experimentais em usinagem de torneamento e nos treinamentos da rede neural.

Capítulo 5 - Resultados e Discussões:

Apresenta os resultados mais significativos dos ensaios, bem como discussões e considerações que se fazem necessários.

Capítulo 6 - Conclusões e Sugestões para Trabalhos Futuros:

Esse capítulo trata da contribuição dessa dissertação, a confrontação com os objetivos anteriormente propostos e sugestões para futuros estudos dentro da área de escopo da dissertação.

CAPÍTULO 2

MONITORAMENTO DO PROCESSO DE USINAGEM

2.1 - INTRODUÇÃO

Os sistemas de usinagem convencionais dependem bastante da intervenção humana para detectar anormalidades, inspecionar a qualidade do produto e controlar o processo.

Em suma, a tomada das decisões e ações cabíveis ainda depende da habilidade do operador nesse tipo de usinagem.

O emprego de centros de usinagem mais automatizados, têm aumentado consideravelmente a partir da década de 60, principalmente com o advento do controle numérico nas máquinas-ferramenta, em decorrência das mudanças dos sistemas de fabricação, cada vez mais exigindo menor tempo de fabricação, lotes pequenos e diversificados, inventários reduzidos ou nulos e uma busca incessante pela garantia da qualidade total [1]. Então é natural que, acompanhando essa evolução, os sistemas de controle de processo de usinagem tenha evoluído a sistemas compatíveis com as novas necessidades.

Além disso, o surgimento de novos materiais de difícil usinagem e de novos e caros materiais de ferramentas exigem uma otimização maior, não se admitindo que trocas de ferramentas sejam feitas antes do momento adequado [2], onerando os gastos com ferramentas e gerando maiores tempos de máquinas paradas.

Por isso, o monitoramento na usinagem de materiais, baseado fortemente em sensoriamento inteligente, que permite

diminuir a intervenção do operador e substituir algumas das funções do homem na produção de bens manufaturados, é hoje uma fonte de pesquisas crescente, tendo-se chegado em alguns casos a ser utilizado em ambientes reais de trabalho na indústria.

Muitas operações antes realizadas pelo homem, já estão sendo realizadas pelas máquinas automatizadas (CNC, por exemplo), mas muitas operações que envolvem tomada de decisão, por exemplo, estabelecimento do momento de troca da ferramenta, bem como a própria troca, ainda permanecem fortemente sob a dependência da experiência e bom senso do operador.

Os sistemas de monitoramento na usinagem, auxiliados por um dos ramos emergentes da inteligência artificial, a Neurocomputação, pode tornar o processo de tomada de decisões mais independente da intervenção humana [3].

Neste capítulo apresenta-se fundamentos do monitoramento e controle do processo na usinagem dos materiais e no capítulo seguinte, introduz-se as redes neurais e a neurocomputação.

O conhecimento dessas ciências é importante para o entendimento dos objetivos propostos por essa dissertação.

2.2 - MONITORAMENTO DO PROCESSO DE USINAGEM

Para todos os processos de usinagem, as paradas de máquina têm origens calcadas majoritariamente na ferramenta, devido ao fim de sua vida causada pelo seu desgaste ou pela sua quebra [2,4,31].

Portanto, o estabelecimento do momento otimizado da troca da ferramenta é o assunto principal desse capítulo.

O monitoramento na usinagem pode ser dependente do tempo, ocorrendo em tempo real (concomitantemente ao processo), ou independente do tempo de execução do processo.

Outra classificação do monitoramento do desgaste e quebra da ferramenta é em direto ou indireto, no que se refere aos parâmetros de medição do desgaste da ferramenta.

Diz-se que o método é direto quando a medição do desgaste é realizado diretamente na ferramenta e indireto quando um outro parâmetro mensurável em tempo real pode ser monitorado e posteriormente correlacionado ao desgaste (ou crescimento da rugosidade superficial da peça, devido ao desgaste).

Ambos os métodos possuem vantagens e desvantagens, levando-se em conta as características requeridas como confiabilidade, custo, repetibilidade em ambientes reais, insensibilidade a ruídos externos e não intrusividade.

Todo sistema de monitoramento e controle da usinagem é constituído de 4 partes, quais sejam: sensor, condicionamento do sinal, modelo e estratégia dos sensores [5]. Os sinais saídos dos sensores muitas vezes não podem imediatamente ser analisados. Antes disso têm que passar por diversos estágios, como amplificação, filtragem, conversão analógico-digital, etc... Ao conjunto destes estágios chama-se condicionamento do sinal.

Após o condicionamento, passa-se à fase de análise do sinal, que pode ser tanto no domínio do tempo quanto no domínio da frequência. No domínio do tempo, ferramentas estatísticas como a raiz quadrada da média (RMS), desvio-padrão ou séries temporais são as mais utilizadas para determinar parâmetros que possam ser utilizados na tomada de decisões.

A transformada de Fourier ("Fast Fourier Transform"-FFT), converte os sinais do domínio do tempo para o domínio da

freqüência, utilizando técnicas de análise modal, para separar as faixas de freqüência constantes do sinal. Normalmente a escolha de parâmetros e faixas de freqüências adequadas é realizada em ensaios prévios, a fim de que durante a operação propriamente dita, tais parâmetros possam ser utilizados nos modelos [6].

Assim, modelos matemáticos correlacionam os parâmetros medidos com os parâmetros a serem monitorados, de modo empírico ou baseados em teorias. Por exemplo, a força de corte pode ser medida diretamente e posteriormente correlacionada com o desgaste da ferramenta (parâmetro que deve ser monitorado), através de uma função matemática.

Depois disso, o sistema deve tomar uma iniciativa (estratégia).

Por exemplo, na iminência da quebra da ferramenta, o sistema pode indicar a anomalia no monitor do computador, fazer soar um alarme, ou diagnosticar a anomalia e propor uma solução.

Também, pode-se lançar mão dos Controles Adaptativos, em que o sistema varia os parâmetros de usinagem e os adapta às novas condições [7].

2.3 MÉTODOS DIRETOS DE MONITORAMENTO

Nos métodos diretos de sensoramento, como mencionado anteriormente, a medição do desgaste é feita diretamente na ferramenta. A séria restrição a esses tipos de sistemas é que a medida direta, por limitações tecnológicas e funcionais não pode ser realizada em tempo real [8].

A vantagem principal sobre os métodos indiretos é que geralmente os tipos diretos têm maior confiabilidade, pois só dependem do parâmetro medido.

Os principais métodos diretos conhecidos levam em conta medidas de forma ou posição da ponta da ferramenta (óptico), tamanho de partículas e radioatividade, variação da resistência da junção peça-ferramenta e dimensões da peça.

Os sensores nestes tipos descritos são em geral mais caros que os sensores dos métodos indiretos e compõem-se por exemplo de voltímetros, câmeras de TV, transdutores e micrômetros, medidores de radioatividade, etc...

2.4 MÉTODOS INDIRETOS DE MONITORAMENTO

Os métodos indiretos, onde um ou mais parâmetros são controlados e monitorados em tempo real e, posteriormente, correlacionados com os parâmetros que realmente influem no desgaste da ferramenta, sofrem do fato de que as medidas são influenciadas por fatores alheios ao desgaste, como por exemplo, variações no material de trabalho, geometria da ferramenta de corte, vibrações do sistema MFDP (máquina-ferramenta-dispositivo de fixação-peça), etc...[8]

Aqui serão apresentados de forma sumária os métodos mais convencionais, com ênfase no método de monitoramento via vibração, utilizado nos experimentos dessa dissertação.

2.4.1. MÉTODO DE MONITORAMENTO INDIRETO POR ESFORÇOS DE CORTE

Dentre os métodos indiretos, esse, em suas diversas formas, é o mais usado, sendo também o mais antigo.

Sua forma mais popular é a medição de forças diretamente através de dinamômetros, que são instrumentos que ao

serem deformados produzem correntes ou cargas elétricas proporcionais às forças que ocasionam a deformação.

As características desejadas de um dinamômetro são: rigidez, sensibilidade, precisão, ausência de sensibilidade cruzada e calibração linear [9,10].

Na usinagem, usa-se com mais frequência dinamômetros piezoelétricos ou com extensômetros. Os piezoelétricos são dotados de cristais que, uma vez deformados, geram um campo magnético proporcional à deformação que o gerou. Os extensômetros são estruturas que variam sua resistência elétrica ao serem excitados (deformados) [9].

A figura 2.1 [8], ilustra um exemplo didático de um circuito comumente usado nas medições dos esforços de corte, consistindo-se em:

- * amplificadores: os sinais de excitação dos dinamômetros são muito baixos e necessitam de amplificação. Se o dinamômetro for piezoelétrico, necessita-se de um amplificador de cargas, cujos sinais de saída serão correntes proporcionais aos campos gerados pelos dinamômetros, só que, amplificado de uma certa magnitude.

- * modulador: transforma o sinal de força (corrente DC) exclusivamente em corrente AC, permitindo o armazenamento do sinal através do gravador, para posterior análise.

- * placa A/D: uma vez que os computadores processam dados digitais, é necessária essa placa para digitalização dos dados dos sinais analógicos que saem do sistema de condicionamento do sinal.




Figura 2.1 - Exemplo de uma montagem para medição de forças de usinagem [8]

2.4.1.1. RELAÇÃO ENTRE FORÇA DE CORTE NA USINAGEM E O DESGASTE DA FERRAMENTA

Diversos autores já pesquisaram a relação entre os esforços de corte e o desgaste da ferramenta. Os principais pontos a serem notados destes trabalhos são:

1) Ocorrendo apenas o desgaste de flanco, à medida que este cresce por causa do atrito entre ferramenta e a peça usinada, crescem também as forças de usinagem [11];

2) Porém, ocorrendo além do desgaste de flanco, também o desgaste de cratera, não ocorre um crescimento tão marcante das forças de usinagem. Isso ocorre porque, quando o desgaste da

cratera passa a apresentar uma dimensão considerável, aumenta o ângulo de saída efetivo da ferramenta, havendo uma estabilização dos valores das componentes de força, pela diminuição dos esforços inerentes à deformação do cavaco;

3) Pela análise do espectro dos sinais de força, Lee et ali [12] postularam que, independente das condições de usinagem, a máxima amplitude se dá na frequência ressonante do porta-ferramenta. Segundo eles, a deformação plástica sobre a ponta da ferramenta em altas temperaturas explica o crescimento constante da força dinâmica, ao qual se segue um decréscimo substancial perto do fim de vida da ferramenta.

2.4.1.2 RELAÇÃO ENTRE ESFORÇOS DE CORTE E CONDIÇÕES DE USINAGEM

Como mencionado anteriormente, o crescimento da força de usinagem não é causado somente pelo aumento do desgaste, mas é influenciado também por variações alheias ao desgaste, que podem mascarar algumas medições dos esforços de corte, que visem monitorar indiretamente os desgastes da ferramenta.

Algumas relações podem ser, entretanto, verificadas.

Chama-se de pressão específica de corte K_s ao quociente entre a força específica de corte e a área efetiva de corte.

A força de corte F_c pode ser calculada por

$$F_c = K_s * A = K_s * h * b \quad [9]$$

onde A é a área da secção de corte ($b * h$), h é a espessura de corte e b é a largura de corte.

Pela figura 2.2, pode-se ver como a pressão específica de corte se comporta em relação à profundidade de usinagem a_p , à espessura de corte h e à velocidade de corte v_c .

Nesta figura pode-se ver que:

- K_s decresce exponencialmente com h e v_c . Porém, quando a velocidade de corte atinge valores típicos de operações com ferramentas de metal duro (acima de 100 m/min), a queda de K_s já não é mais tão acentuada, pois já se está naquela região onde a curva $K_s \times v_c$ é quase paralela ao eixo de v_c . É bom salientar que, apesar de K_s decrescer com h , a força de corte cresce, pois a área da secção de corte ($A = b \cdot h$) cresce. Porém, o crescimento da força com h não é acentuado devido a esta diminuição de K_s .




Figura 2.2 - Influência das condições de usinagem na pressão específica de corte K_s [9]

Quanto a a_p , como esse parâmetro não influencia K_s , há um aumento da força diretamente proporcional à mesma a_p .

Para atenuar a influência das condições de usinagem no monitoramento por esforços de corte, a literatura recomenda 3 abordagens distintas [13,14]:

1) Relacionar os valores das componentes da força de usinagem no início e no fim da vida da ferramenta com as condições de usinagem;

2) Análise do espectro de frequências. Aqui se escolhe a faixa de frequências que somente é influenciada pelo desgaste da ferramenta;

3) Relacionar os componentes da força de usinagem - a divisão de um componente da força por outro, (por exemplo, força de corte por força de avanço) pode muitas vezes, evitar a influência das condições de usinagem.

2.4.1.3. ESFORÇOS DE CORTE E QUEBRA DA FERRAMENTA

O monitoramento da quebra da ferramenta, a par do monitoramento do desgaste, é muito importante na usinagem, pois a detecção prévia de uma quebra pode evitar danos catastróficos ao conjunto máquina-ferramenta-peça.

Uma relação importante [15] diz respeito à força de avanço durante uma quebra da ferramenta, num processo de torneamento (figura 2.3).

Vê-se que quando ocorre uma quebra, rapidamente o valor dessa força cai, até que uma nova rotação seja efetuada, havendo um crescimento da mesma, devido ao novo contato da peça com a ferramenta.




Figura 2.3 - Força de avanço no instante da quebra da ferramenta [15]

Sabendo-se disso, o sistema pode:

- 1) interromper o processo no intervalo de tempo no limiar do crescimento súbito da força;
- 2) interromper o processo antes da quebra, ao se atingir um valor limite para a força.

2.4.2. MONITORAMENTO DOS ESFORÇOS DE CORTE VIA PARÂMETROS ELÉTRICOS

A medição de parâmetros elétricos da máquina-ferramenta remete indiretamente à medição por método indireto dos esforços de corte, uma vez que a potência elétrica dos motores de

acionamento da máquina-ferramenta é diretamente proporcional à potência mecânica gerada pela mesma.

Um exemplo simples pode ser dado pelas equações citadas em [9]:

Dados os parâmetros elétricos R e I , resistência elétrica e intensidade de corrente do sistema e η , o fator de rendimento do mesmo:

$$R * I^2 = K_s * b * h * v_c / \eta$$

e como $F_c = K_s * b * h$, temos que:

$$R * I^2 = F_c * v_c / \eta$$

Mantendo-se constantes b , h , η e v_c , temos que os parâmetros elétricos R e I são proporcionais à força de corte F_c .

Segundo alguns autores, como Dan, Stein, Shin e Churn, a sensibilidade da corrente elétrica é muito alta para a quebra da ferramenta, mas nem tanto em relação ao desgaste, ou seja, é muito adequado para torneamento de desbaste, onde os valores de desgaste não são tão imprescindíveis, pois não há muita exigência na qualidade superficial da peça.

A figura 2.4, extraída de [13] apresenta níveis de corrente para alguns estágios de desgaste da ferramenta, para uma dada condição de usinagem.

Conclui-se desse gráfico que:

1) Entre uma ferramenta recém-afiada e um corte intermediário não há uma diferença notadamente grande para os valores de corrente;

2) Entre esses últimos e a quebra da ferramenta há uma diferença bastante significativa;

3) Pode-se então, adotar métodos de interrupção do desbaste no valor de corrente um pouco abaixo do valor limiar para a quebra.




Figura 2.4 - Valores da corrente elétrica da máquina-ferramenta em diversos instantes da vida da ferramenta [13]

2.4.3. MONITORAMENTO INDIRETO VIA EMISSÃO ACÚSTICA

Entre os monitoramentos por sensoriamento indireto na usinagem, o emprego do método via emissões acústicas é muito difundido, acumulando uma série de vantagens em relação aos outros métodos indiretos, que podem ser resumidos em:

1) captam sinais de alta frequência (50 kHz a 1 MHz), sendo portanto, robusto a ruídos externos, facilmente filtráveis.

2) seus sensores são pequenos (não intrusivos), apresentando um relativo baixo custo e tamanho, além de extrema simplicidade.

3) As fontes de emissão acústica têm relação direta com o processo de corte de usinagem.

Entende-se por emissão acústica (E.A.) [16,17,18,19]: "as ondas de tensão elástica geradas como resultado da liberação rápida de energia de deformação dentro de um material submetido a um estímulo externo, devido ao rearranjo de sua estrutura". Tais ondas causam deslocamento na superfície do material, detectável por um sensor piezoelétrico que converte os deslocamentos em sinais elétricos. A frequência atingível chega à ordem de MHz.

A emissão acústica é gerada pelo próprio material deformado, portanto não há mecanismo de controle na geração do sinal, ao contrário do processo de ultrassom, onde a onda acústica é gerada em uma fonte externa e depois introduzida no material.

Pode-se classificar os sinais de E.A. em 2 tipos: contínuo e de pico [17,18,19].

a) sinal contínuo : associado à deformação plástica dútil, devido à movimentação de discordâncias e de contornos de grão do material.

b) sinal de pico : associado ao crescimento de trincas em materiais [20] que ocorrem na quebra do cavaco e no lascamento e quebra da ferramenta.

As 3 principais fontes de geração de E.A. na usinagem são as 3 zonas de deformação do processo de formação do cavaco, mostradas na figura 2.5.




Figura 2.5 - Áreas de geração de E.A. na formação do cavaco [17]

A zona primária ou zona de cisalhamento é onde começa e termina a formação do cavaco. A zona secundária é a área de contato cavaco-ferramenta. Ocorre deformação do cavaco devido a seu atrito com a superfície de saída da ferramenta. A zona terciária é a região de contato ferramenta-peça, onde ocorre deformação pelo atrito da peça com a região desgastada da superfície de folga da ferramenta.

Além do cisalhamento do cavaco e dos atritos cavaco-ferramenta e ferramenta-peça (que constituem as 3 zonas de deformação), outros fenômenos também geram E.A., como, por exemplo, a quebra do cavaco.

Didaticamente apresenta-se uma montagem experimental na figura 2.6, bastante comum no monitoramento de usinagem por E.A.

Comenta-se aqui alguns dos equipamentos, por terem características peculiares [19,21] :

a) Sensores:

Geram um sinal elétrico ao serem estimulados por uma onda acústica. Um sensor ideal produz uma curva de voltagem x tempo idêntica à curva amplitude x tempo da onda, no ponto onde se situa o sensor. No caso do torneamento, o melhor lugar para se colocar o sensor é a parte traseira do porta-ferramenta (apesar do cabo que sai do sensor e vai para o pré-amplificador impedir a rotação da torre porta-ferramentas).

Os sensores de E.A. baseam-se em vários princípios físicos, mas a grande maioria é de natureza piezoelétrica.




Figura 2.6- Típica montagem experimental para o monitoramento das E.A. [8]

b) Pré-amplificador e Amplificador:

Os sinais saem do sensor e, ao percorrerem um caminho longo até o amplificador, têm grande perda de voltagem. Assim, é usual se colocar um pré-amplificador de ganho fixo perto do sensor (cuja frequência de resposta é da ordem de 20 kHz a 2 MHz) e um amplificador com ganho variável junto aos demais instrumentos de condicionamento do sinal.

c) Filtros de frequência:

É conveniente filtrar os componentes de baixa frequência do sinal, pois na E.A. trabalha-se com sinais de alta frequência.

d) Osciloscópio:

Adequado para análise do processo em se acompanhando visualmente a variação do sinal.

e) a digitalização dos sinais de E.A. em tempo real devido à alta frequência do sinal é muito difícil. Porém, 2 métodos podem ser usados para atenuar ou eliminar esse inconveniente:

1) passar o sinal que sai do amplificador por um instrumento cuja saída é o valor RMS do sinal de entrada, tendo o sinal de saída frequência menor devido à constante de tempo que o instrumento tem (tempo para amostrar o sinal vindo do amplificador e calcular o RMS de saída);

2) gravar o sinal do amplificador em um gravador de vídeo, por exemplo, para análise posterior do sinal.

2.4.3.1. INFLUÊNCIA DAS CONDIÇÕES DE USINAGEM E DA GEOMETRIA DA FERRAMENTA NOS VALORES DE E.A.

Muitos estudos foram realizados analisando a influência das condições de usinagem e da geometria da ferramenta, em

parâmetros de E.A, pois a variação destes pode confundir o sistema de monitoramento na detecção do desgaste da ferramenta

Um trabalho de Blum e Inasaki [18] apresenta esse tema (figura 2.7). O modo de E.A. (parâmetro semelhante ao RMS do sinal de E.A.):

- cresce linearmente com o aumento da vc ;
- decresce com o crescimento do avanço e do ângulo de saída da ferramenta;
- quase não é influenciado pela profundidade de usinagem.




Figura 2.7 - Influência da velocidade de corte e do avanço no sinal de E.A. [18]

2.4.3.2 MONITORAMENTO DO DESGASTE E QUEBRA DA FERRAMENTA VIA E.A.

Esse é o campo da E.A. mais utilizado e estudado até os dias de hoje.

A figura 2.8 mostra o crescimento do modo de E.A. à medida que o desgaste de flanco cresce [18]. Esse comportamento é semelhante usando-se outros parâmetros de medição de E.A.




Figura 2.8 - Influência do desgaste de flanco nos valores de E.A. [18]

A quebra da ferramenta produz um sinal bem característico, como se vê na figura 2.9. No instante de quebra da ferramenta um grande pico no valor de modo de E.A. aparece, ocorrendo igualmente um pico no caso de lascamento da ferramenta [17], mas de valor menor.




Figura 2.9 - Sinal de E.A. no momento da quebra da ferramenta [17]

2.4.4. MONITORAMENTO INDIRETO DA USINAGEM VIA VIBRAÇÕES

Esse método, apesar de bastante pesquisado nos últimos anos, ainda não alcançou a aplicabilidade em ambientes reais, tal como já ocorre com alguns trabalhos de monitoramento via E.A.

O monitoramento de sinais de vibração em tempo real, alcançando faixas de frequência bem menores que no caso de emissões acústicas podem ser de grande importância no acompanhamento do processo de desgaste da ferramenta, baseado no fato de que a vibração emitida pelo par ferramenta-porta-

ferramenta traz informações sobre as condições da ferramenta e do processo de formação do cavaco.

A maior dificuldade na utilização do método via vibrações é identificar e separar a faixa de frequência realmente afetada pelo processo de desgaste e quebra da ferramenta, pois poderia ocorrer mascaramento devido a vibrações geradas por fenômenos que não sejam relacionadas ao desgaste e quebra da ferramenta, falseando-se os objetivos a que esse método se propõe.

Existem, segundo Shaw [10], dois tipos de vibração na usinagem : forçada e auto-excitada.

a) Vibração forçada:

Ocorre quando a frequência natural do sistema M-F-D-P (Máquina-Ferramenta-Dispositivo de Fixação-Peça) se aproxima da frequência de um carregamento externo cíclico, como folga nos mancais de rolamentos, desbalanceamentos de eixos em processos de torneamento ou a sobreutilização da capacidade do equipamento.

Esse tipo de vibração pode ser atenuado segundo Jacobsen e Arye [22] , através da supressão das forças excitantes cíclicas (quando possível), evitando-se a coincidência entre as frequências ressonantes natural e da carga (diminuindo assim a amplitude), e/ou aumentando-se a rigidez e o amortecimento do sistema.

Essa categoria não interessa ao sensoriamento da usinagem, pois estas não estão diretamente relacionadas com o mecanismo de desgaste da ferramenta.

b) Vibração auto-excitada:

Conhecida por "chattering", é devida à maior absorção do que desprendimento de energia num ciclo vibracional simples.

Ocorre em choques, encontro de incrustações ou pontos duros no material durante a usinagem, no processo de formação do cavaco, na usinagem descontínua, no atrito, etc. [9,23].

Portanto, as vibrações que ocorrem dos contatos ferramenta-peça e cavaco-ferramenta, que têm a ver com o desgaste e quebra da ferramenta pertencem a essa categoria.

2.4.4.1. INFLUÊNCIA DAS CONDIÇÕES DE USINAGEM NA ESTABILIDADE DO SISTEMA

A estabilidade do sistema Máquina-Ferramenta-Dispositivo-Peça depende de fatores como as condições de corte e geometria de usinagem.

Algumas conclusões dos trabalhos de Arshinov et ali [24] são sumarizados a seguir:

1) A vibração está associada ao material da peça a ser usinada. Em geral, com o aumento da dureza e da resistência do material, há redução das vibrações;

2) Para velocidades de corte baixas, a vibração do sistema cresce com o aumento da velocidade. A partir de um determinado valor da velocidade as vibrações tendem a decrescer. Isso ocorre devido à formação da aresta postiça de corte (A.P.C.). O comportamento da rugosidade superficial da peça acompanha o da vibração, isto é, em altas velocidades de corte, a rugosidade é menor devido às menores vibrações;

3) Há tendência das vibrações do sistema aumentarem com o aumento da profundidade da usinagem;

4) Em comparação com a velocidade de corte e profundidade de usinagem, pode-se desprezar os efeitos do avanço nas vibrações;

5) Quanto maior o raio de ponta, maior é a vibração do sistema. Isso devido ao aumento da largura do cavaco e diminuição de sua espessura média, com conseqüentes aumento da pressão específica de corte K_s e dos esforços de corte;

6) O ângulo de saída da ferramenta não influi significativamente na vibração do sistema (isso é particularmente válido para ângulos de 3 a 20 graus);

7) Ferramentas chanfradas tendem a diminuir a vibração do sistema, ou seja, a forma da ferramenta também é influente na vibração;

8) No torneamento de eixos finos e compridos ou de furos de diâmetro pequeno, é extremamente difícil se evitar as vibrações, facilitando as condições de quebra da ferramenta.

2.4.4.2. MONTAGEM E INSTRUMENTAÇÃO

Apresenta-se aqui, de forma didática, uma montagem completa de um sistema experimental de monitoramento via vibração, para processos de torneamento. Essa montagem, com algumas variantes, é comumente utilizada neste método (figura 2.10). Um breve comentário sobre alguns dos equipamentos usados:

1) Os amplificadores, a exemplo dos outros métodos, têm por finalidade amplificar a um nível adequado os sinais de saída dos sensores (na forma de voltagem).

2) Os filtros de frequência têm por finalidade restringir a uma determinada faixa, as frequências do sinal, para com isso, eliminar sinais externos que não interessam ao objeto do monitoramento.

Os filtros geralmente são classificados em 3 categorias: passa-baixa (que filtra os sinais a partir de uma dada frequência superior), passa-alta (que filtra os sinais com frequência inferior a um dado valor) e a passa-banda, que deixa passar unicamente os sinais contidos numa determinada faixa de frequência [6].

3) O analisador eletrônico de sinais possibilita, via hardware, a construção do espectro de frequências do sinal.

4) Os acelerômetros piezoelétricos [25] são medidores (sensores) da vibração, e têm princípio piezoelétrico. Ou seja, seus cristais ao serem excitados geram uma força eletromotriz proporcional à aceleração do movimento mecânico do corpo em contato com ele (daí a origem do nome acelerômetro), e que é uma indicação da vibração instantânea deste corpo.




Figura 2.10 - Montagem experimental típica para o sensoramento da vibração [8]

2.4.4.3. ANÁLISE DO SINAL E ESTRATÉGIA DE MONITORAMENTO VIA VIBRAÇÃO

Como em outros métodos, a análise do sinal de vibração pode ser feita no domínio do tempo ou da frequência.

No domínio do tempo, os parâmetros estatísticos (média, desvio-padrão, RMS, velocidade instantânea do porta-ferramentas) são mais utilizados.

A análise modal é a técnica mais utilizada no domínio da frequência, onde a densidade de potência espectral (PSD) é uma função que representa a distribuição de energia sobre o domínio da frequência [6].

Em suma, na vibração de um corpo, há geração de infinitas frequências diferentes, cada qual com sua própria amplitude. A PSD faz-se ter uma idéia do valor desta amplitude para cada faixa de frequência.

A faixa de frequências adequada para o estudo do monitoramento via vibrações vai de 0 a 20000 Hz, embora uma faixa de até 8 kHz seja adotado pela maioria dos pesquisadores.

Na tabela 2.1, apresenta-se as faixas de frequência sensíveis ao desgaste segundo alguns pesquisadores.

Como citado anteriormente, justamente a determinação da faixa de frequências sensíveis ao desgaste é a principal dificuldade do pesquisador, porém uma vez determinada a faixa o monitoramento se torna muito atraente. Alguns autores citam que esta faixa está associada à frequência natural do porta-ferramenta, que pode ser facilmente encontrada, bastando para isso causar um impacto no porta-ferramenta, e, através do próprio sistema de monitoramento, encontrar sua frequência natural, ou seja, a

frequência do sinal de resposta causado na ferramenta pelo impacto.

PESQUISADOR	FAIXA DE FREQUÊNCIA SENSÍVEL
Xu-Zhang-Jiang [26]	0-117Hz 510 Hz
Rao [27]	1850 Hz 3200 Hz 4800 Hz
Akihiko-Fujita [28]	500-800 Hz
Pandit-Kashou	4300-4700 Hz
Weller-Schrier- Weichbrodt [29]	0-4000 Hz
Sokolowski-Kosmol	0-600 Hz 5000- 6000 Hz
Martin-Drapier-Mutel [30]	2000-2500 Hz
Fang-Yao-Arndt	0-150 Hz 2000- 2500 Hz

Tabela 2.1 - Faixas de frequência de vibração sensíveis ao desgaste, segundo diversos autores.

Weller [29], sugeriu um procedimento para a análise do sinal de vibração na usinagem, qual seja:

a) divide-se o sinal, através de filtros de frequência, em duas faixas, uma de 0 a 4 kHz e a outra de 4 a 8 kHz;

b) esses sinais passam por um circuito que divide o valor do sinal de um pelo outro, obtendo-se uma relação entre as duas;

c) pelos resultados obtidos, o sinal da faixa de frequências mais alta não se altera com o desgaste, o que ocorre na faixa mais baixa;

d) quando tal relação chega a um nível pré-estabelecido, emite-se um sinal indicando ferramenta gasta.

Rao [27] descreveu uma técnica computacional para monitoramento em tempo real do desgaste de flanco em operação de torneamento baseado no índice WI de desgaste ("Wear Index"). Esse índice WI é uma medida de resistência, na interface peça-ponta da ferramenta ao longo do flanco, para as oscilações do porta-ferramenta durante a usinagem. O aumento do desgaste do flanco resulta numa área crescente de contato entre a interface. Isso significaria um índice WI crescente, proporcional ao comprimento do desgaste do flanco.

O WI é dado pela razão entre a Amplitude da força na frequência natural do porta-ferramenta e a Amplitude da vibração na mesma frequência

Segundo o autor, esse sistema de monitoramento foi capaz de prever a troca da ferramenta de corte com precisão de cerca de 95%.

Akihiko et alli. [28] propuseram um detector de falhas da ferramenta de corte em tempo real. Numa primeira fase, eles mediram as vibrações geradas durante a usinagem e analisaram os dados via computador, usando a transformada rápida de Fourier (FFT) e os sinais RMS. Posteriormente desenvolveram o detector, que continha um módulo de aquisição de vibrações, um meio de processamento dos sinais e circuitos lógicos. Esse detector calculava a relação entre o sinal da fonte e um valor padrão a fim de que propiciasse seu uso tanto para condições normais de corte em aço AISI 1045, quanto em condições pesadas (elevados avanços e profundidades de usinagem para liga aço-cromo) e também para a furação.

Desse modo, o detector emitia um sinal em forma de pico na iminência de falha da ferramenta.

Jiang et alli. [26] propuseram um sistema de monitoramento do desgaste que detectava o estágio de micro-fraturas (entre o desgaste normal e o desgaste rápido) das peças usinadas por torneamento cilíndrico, através dos sinais de vibração. Basearam-se na composição da frequência dos sinais e suas mudanças de padrão, pois, segundo eles, a composição da distribuição da energia do sinal varia regularmente com o desenvolvimento do desgaste da ferramenta de corte.

Martin et alli. [30] descreveram uma relação entre os sinais de vibração de uma ferramenta (em torneamento) e seu desgaste de flanco para estabelecer uma medida que seja característica do estado de desgaste. Eles constataram que, quando a relação entre o sinal da ferramenta gasta e o sinal fornecido pela mesma ferramenta ainda nova atinge a razão 1:10, convém se trocar a ferramenta.

Sokolovski et alli. [31] fizeram análises do sinal de vibração para detecção do desgaste de flanco da ferramenta. As características espectrais da vibração foram usadas como base para determinar relações entre o fator de desgaste da ferramenta e a amplitude de vibração. A forte correlação por eles demonstrada entre essas relações e o desgaste lhes permitiu concluir que essa análise era muito promissora para a detecção do desgaste de flanco da ferramenta.

Bonifácio [32] mostrou que o monitoramento da vibração da ferramenta é adequado para se estipular o fim de vida da mesma em processos de torneamento cilíndrico de acabamento. Ele recolheu os sinais de vibração do porta ferramenta e analisou no domínio do tempo, através da raiz quadrada da média (RMS) e no

domínio da frequência pela transformada rápida de Fourier (FFT), sempre comparando com os valores de rugosidade da peça.

Entre as conclusões, as principais foram:

- A rugosidade média e a rugosidade máxima da superfície da peça experimentaram um crescimento muito acentuado quando a ferramenta atinge determinado estado de desgaste;

- A mesma tendência de crescimento abrupto se verificou para os sinais de vibração medidos em 2 direções (de corte e de avanço);

- Assim, através do monitoramento via vibrações, pode-se determinar de modo satisfatório o momento de troca da ferramenta;

CAPÍTULO 3

REDES NEURAIIS

3.1. INTRODUÇÃO - O QUE É COMPUTAÇÃO NEURAL

A computação neural é uma técnica de inteligência artificial baseada no funcionamento do cérebro do homem.

As redes neurais, que são aplicações da neurocomputação, possuem um conjunto de capacidades com resposta adaptativa ao universo de dados que lhe são fornecidos.

Uma comparação com a computação tradicional é bastante conveniente para acentuar as diferenças entre essa e a neurocomputação [3]:

1) Na computação tradicional, o processamento de dados e informações é de modo programado, ou seja, o processamento é realizado através de um universo de regras, rotinas pré-estabelecidas, baseando-se numa forma totalmente lógica. A neurocomputação, ao contrário, gera suas próprias regras através de uma de suas capacidades, o aprendizado. Exemplificando, naquele tipo de computação, o funcionamento do sistema é baseado em um algoritmo projetado, codificado na forma de um "software". Já nas redes neurais, não existe execução de programas, mas as regras são geradas através do aprendizado, através de exemplos que lhe são mostrados.

2) Nos sistemas tradicionais, pequenos danos na memória podem causar a completa inutilização do processo. As redes neurais, ao contrário, são tolerantes a falhas, devido à topologia das redes permitir a inutilização de elementos processadores. Além disso, existe nelas a propriedade de generalização, que consiste em fornecer respostas razoáveis, ainda que lhes sejam apresentados exemplos nunca antes analisados, com ruído ou incompletos. A perda de números maiores de elementos causa perda de rendimento, mas não a perda do processo.

3) Portanto, as redes neurais diferem substancialmente da computação tradicional, pois não executam programas, mas "deixam-se levar", comportando-se face a um conjunto de dados, reagindo, aprendendo e esquecendo, simulando o comportamento do cérebro humano, baseado na evidência neurológica.

As redes neurais, enfim, são uma resposta alternativa à computação programada, que vem merecendo a atenção de pesquisadores de forma bastante crescente ultimamente, após seus estudos terem passado por um período de arrefecimento, conforme será visto num item adiante.

3.2. ANALOGIA COM O CÉREBRO [3]

Como foi visto anteriormente, as redes neurais simulam o funcionamento da coordenação nervosa, que é o controle das funções de um organismo, desempenhado pelo sistema nervoso. Por isso, necessário se faz a apresentação de alguns conceitos dentro deste contexto.

O sistema nervoso é composto por células altamente diferenciadas, denominadas de neurônios. Os neurônios são constituídos pelo corpo celular, pelos dendritos e pelos axônios.

Os neurônios são elementos processadores simples, que recebem e combinam impulsos elétricos de muitos outros, através dos dendritos, que são prolongamentos do corpo celular, geralmente bastante ramificados e curtos. O axônio é, em contra-partida, quase sempre pouco ramificado e muito longo.

A transmissão de informações entre os neurônios dos sistemas nervosos se dá através das sinapses, que são o elo de ligação entre os ramos do axônio do neurônio transmissor e os ramos dos dendritos do neurônio receptor.(figura 3.1) [33].




Figura 3.1 - Representação gráfica de um neurônio [3]

A transmissão das informações se dá por impulsos (no sentido do axônio para o dendrito) de natureza química, cujos efeitos são de origem elétrica, podendo ser mensuráveis.

O axônio na região sináptica descarrega uma substância transmissora, geralmente de natureza hormonal, como a acetilcolina, que se difunde na região sináptica e estimula os dendritos do

neurônio seguinte, propiciando novo impulso que será passado para outros neurônios, de forma encadeada e muito rápida.

Imitando os neurônios biológicos, as redes neurais são constituídas de elementos processadores simples. Nestes, o equivalente ao axônio é uma conexão de saída, e os dendritos são representados pelas diversas conexões de entradas.

O elemento processador combina, geralmente por meio de uma soma ponderada, os valores de entrada. A cada valor de entrada X_i é associado um peso de conexão W_i . Uma função de transferência $Y = f(I)$ modifica os valores da combinação $I = \sum W_i * X_i$, de tal forma que Y , quando atingir um determinado nível, passa a ser a saída e esse valor passa pela conexão de saída para outros elementos processadores. (figura 3.2) [33].




Figura 3.2 - Representação do elemento processador de uma rede neural [33]

Uma rede neural típica tem muitos elementos processadores interligados, formando grupos, ditos camadas.

As camadas podem estar parcial ou totalmente interligadas, mas duas delas têm ligação com o meio exterior [34]:

1) a camada de entrada, na qual apresenta-se ou introduz-se os dados à rede;

2) a camada de saída, através da qual se obtém os resultados, ou seja, a resposta aos dados que são apresentados.

Outras camadas, situadas entre as camadas de entrada e a de saída são as camadas internas, ditas escondidas ou intermediárias. Essas camadas processam representações internas. Uma rede pode ter, teoricamente, uma quantidade ilimitada dessas camadas, mas numa precisão tal que já não seja necessária. Além disso, experimentos de Dornfeld [35,36,37] apontaram que a partir da sexta camada escondida em diante até a décima, a taxa de precisão foi sucessivamente decrescente, como se pode ver na tabela 3.1. Além disso, a demora no processamento aumenta consideravelmente com o aumento da quantidade de camadas escondidas (ver figura 3.3 [33]).

NÚMERO DE CAMADAS ESCONDIDAS	TAXA DE RECOGNIÇÃO CORRETA (%)
2	94
4	96
6	96
8	95
10	91

Tabela 3.1 - Precisão de uma rede neural em função do número de camadas escondidas [37]

Executar um exemplo numa rede neural é submetê-la a um processo de aprendizagem. Isso quer dizer que antes de

entrarem em funcionamento, as redes devem ser submetidas a um período de aprendizado [34]




Figura 3.3 - Representação de uma rede neural típica [33]

O aprendizado é, em suma, a adaptação ou modificação dos pesos para que os resultados na camada de saída sejam convenientes, em face aos dados de entrada.

Existem vários algoritmos de aprendizado para as redes neurais, mas é possível, treinando-se um mesmo exemplo com algoritmos diferentes, chegar-se a resultados incrivelmente semelhantes.

Quanto ao treinamento, as redes neurais podem ser tratadas de duas formas [3]:

a) treinamento supervisionado: o usuário apresenta à rede o conjunto de dados de entradas, bem como os dados de saída requeridos. Os pesos são ajustados de acordo com o algoritmo de aprendizado, em direção à saída requerida.

b) treinamento não supervisionado: neste, apenas o conjunto de dados de entrada é fornecido à rede, a qual processa esses dados, utilizando seus próprios padrões e critérios e fornecendo ela mesma os resultados de saída convenientes.

3.3. CONSTITUIÇÃO DAS REDES NEURAIS

Existem alguns conceitos fundamentais que caracterizam ou definem as redes neurais segundo as propriedades que as regem: os elementos processadores, a topologia e as regras de aprendizado. Segue-se uma descrição sucinta de cada um destes elementos:

3.3.1. OS ELEMENTOS PROCESSADORES

Como mencionado antes, um elemento processador é o equivalente a um neurônio biológico simples.

A cada sinal de entrada X_i , é associado um peso associado W_i (os pesos podem ser pré-determinados ou totalmente arbitrários) e é computada a entrada efetiva, uma soma ponderada $I = \sum X_i * W_i$. Através de uma função da entrada efetiva, obtém-se a saída $Y = f(I)$, que é a resposta aos dados de entrada. A função deve ser contínua e derivável em todo o seu domínio, sendo as mais comuns a função sigmóide, a função tangente hiperbólica e a função seno [3,34].(ver figura 3.2).

3.3.2. A TOPOLOGIA

A maneira como os elementos processadores de uma rede estão interligados definem a topologia da rede.

Assim como existem diversos tipos de neurônios biológicos, cada um altamente especializado em alguma função, as diferentes topologias de redes fazem paralelo com esses neurônios, formando uma correspondência ao sistema nervoso humano.

Entre as topologias mais importantes, podemos citar as de retroalimentação (feed-forward), as de aprendizado competitivo e as redes recorrentes.(figura 34).




Figura 3.4-Algumas das diferentes topologias das redes neurais [33]

3.3.3. AS REGRAS DE APRENDIZADO

As redes neurais têm uma regra de aprendizado que lhes possibilita a capacidade de aprender. Como visto, a saída da rede é função da soma ponderada da entrada. Na concepção da rede essa função é mantida geralmente fixa. Em consequência, modificar os valores de saída do elemento processador, significa mudar os pesos das entradas.

Justamente a existência de uma regra para essa modificação é que permite o aprendizado da rede.

Entre os algoritmos de aprendizado, o mais comum é o algoritmo da regra Delta, desenvolvido por Widrow e Hoff, na década de 60 [3].

Existem várias formas de apresentação da regra delta. Uma maneira bastante simples, para efeitos didáticos, é mostrada abaixo [3]:

$$W = W_{ant} + K_1 * \epsilon * (y - y') + K_2 * (W_{ant} - W_{pen})$$

onde:

W é o peso atual

W_{ant} é o peso anterior

K_1 é a constante de aprendizado

ϵ é o erro entre o valor desejado e o valor real

y é o valor real

y' é o valor desejado

K_2 é a constante de momento

W_{pen} é o penúltimo peso

$(W_{ant} - W_{pen})$ é denominado momento

Essa diferença $(W_{ant} - W_{pen})$, conhecida como momento, tem por finalidade possibilitar o cálculo menos sensível a variações.

A finalidade da regra Delta, bem como de outras regras de aprendizado, é tornar mínimo a raiz quadrada do erro médio RMS (root mean square).

O RMS em sua forma simples é dada por:

$$\text{RMS} = \sqrt{(1/n) \sum (y-y')^2}$$
, sendo que n é o número de exemplos apresentados à rede.

3.4. LINHA EVOLUTIVA DA NEUROCOMPUTAÇÃO :

Com o propósito de mostrar alguns dos principais e marcantes desenvolvimentos em redes neurais, apresenta-se aqui, de modo sumário, algumas das principais contribuições nesse campo.

Na década de 40, concomitantemente à evolução das pesquisas em sistemas de computação digital, que culminou no computador digital de Von Neumann (1946), começaram os primeiros trabalhos sobre redes neurais [34].

Um trabalho de McCulloch & Pitts (1943) [38], pode ser considerado o marco inicial nas pesquisas em redes neurais. Aí foi apresentado um modelo simples do neurônio, abrindo interesses em pesquisas nesta área.

A primeira simulação em “software” das redes neurais foi apresentado por Rochester (1956), numa das primeiras conferências sobre inteligência artificial.

No ano seguinte, Rosenblatt apresentou o primeiro projeto em neurocomputação, o PERCEPTRON [39]. Esse classificava padrões, podendo identificar formas geométricas. Fotocélulas foram ligadas a elementos processadores, que recebiam impulsos elétricos. A resposta seria produzida quando a entrada sobrepujasse um determinado nível.(figura 3.5)[34].




Figura 3.5 - O Perceptron original [34]

As redes de Perceptrons são totalmente “feed-forward” (retro-alimentação), não aceitando realimentação. Possuem 3 camadas, 1 de entrada e uma de saída e mais uma camada detetora de características. A saída nos Perceptrons é sempre zero ou um. Um se $\sum W_i * X_i > 0$ e zero se $\sum W_i * X_i < 0$. Os pesos do elemento processador são modificados de acordo com a regra : $W = W_{antigo} + (y - y') * x$, sendo que y' e y são os valores real de saída e o valor correspondendo à entrada x , respectivamente.

Em 1959 surgiu o ADALINE (Adaptive Linear Algorithm), fundamentado em elementos processadores adaptativos lineares, surgindo posteriormente uma nova versão com 2 camadas, a MADALINE (Multiple Adaline). Possibilitava reconhecimento de fala, objetos, previsões do tempo [3,34].

Em meados de 60, Minsky e Papert demonstraram a limitação do Perceptron original de Rosenblatt em resolver uma função simples como o ou-exclusivo XOR (ver tabela 3.2). A topologia da rede com uma camada de entrada e outra de saída não permitia que a função XOR fosse linearmente separável.

X_1	X_2	XOR
0	0	0
0	1	1
1	0	1
1	1	0

Tabela 3.2 - A função X exclusivo (XOR)

Mais tarde, redes de mais camadas foram surgindo e provou-se que Perceptrons de uma camada intermediária (no mínimo) podem realizar qualquer função. Vê-se na figura 3.6.a que não é possível traçar uma linha separando os valores zero de um lado da linha e os valores 1 do outro lado. Isso quer dizer que a função não é linearmente separável. Portanto, introduzindo uma camada intermediária, estendemos a rede a um Perceptron multi-camadas, e o problema XOR pode ser resolvido. A figura 3.6.b demonstra que as 4 conexões de entrada são agora associadas a um espaço tri-dimensional definido pelas 2 camadas (de entrada e de saída) mais uma única camada intermediária. Esses 4 pontos são agora facilmente separados por um plano linear em 2 grupos, como desejado.

Esses estudos de Minsky e Papert, que culminaram no trabalho "Perceptrons", em 1969, [40] mostrando as limitações do Perceptron original, arrefeceram as pesquisas em redes neurais, sendo que somente alguns pesquisadores insistiram com sucesso nos estudos, destacando-se os exemplos a seguir:




Figura 3.6.a - A função XOR é não separável linearmente

[34]




Figura 3.6.b - A resolução do problema XOR através da introdução de mais uma camada escondida [34]

Na década de 70, o finlandês Kohonen [41], desenvolveu o princípio do aprendizado competitivo, em que os elementos processadores competem por ter o direito a responder à dada entrada, sendo que o vencedor pode modificar os pesos de suas entradas respondendo a valores próximos a esta com mais força. Os elementos processadores próximos ao vencedor podem aprender, mas nos demais ocorre um efeito de inibição.

Em suma, o elemento vencedor é aquele cujo conjunto de pesos W_i está mais próximo do valor de entrada X .

Tal contribuição culminou na rede neural de Kohonen, conhecido como Mapas Auto-Organizáveis, cuja maior diferença com a maioria das redes neurais é que ela é não supervisionada.

Nas redes de Kohonen há mapas bi-dimensionais das características dos dados de entrada, em concordância com a ordem. A topologia dos mapas auto-organizáveis é ideal para problemas de otimização envolvendo disposições hierárquicas (figura 3.7).




Figura 3.7 - A rede hierárquica de Kohonen [33]

Há duas camadas nesta rede, a camada de entrada e a camada de Kohonen.

Sua regra de aprendizado faz com que o elemento vencedor tenha seus pesos mais próximos aos valores de entrada, através da fórmula Euclideana de distância:

$$D_i = | X - W_i |$$

Existe um mecanismo de espalhamento nesta rede, que faz com que elementos que vençam muito frequentemente tenham seus conjuntos de pesos aumentados, de forma que diminuam suas chances de vencer novamente, ocorrendo uma distribuição espalhada dos elementos vencedores.

O NEOCOGNITRON, de Fukushima, surgiu nos anos 80 e é uma versão aperfeiçoada de seu COGNITRON original (1975).

O Neocognitron [34,41,47] permite aplicações em reconhecimento visual que permite incorporar escala, rotação e translação, em especial de caracteres alfa-numéricos. O caractere de entrada pode estar distorcido ou com ruído, mas assim mesmo o Neocognitron é robusto e insensível a esses problemas.

A família de redes ART (ART-1, ART-2, ART-3) é outro grupo de redes que, a exemplo das redes de Kohonen, possui aprendizado não supervisionado.

A idéia básica das redes ART [3,34,41] surgiu no meio da década de 70, mas pode-se dizer que os modelos originais, propostos por Carpenter e Grossberg, surgiram na década de 80.

Ver-se-á aqui somente a rede ART-1, que classifica padrões binários. (A rede ART-2 classifica padrões analógicos).

A ART-1 consiste de 2 camadas de neurônios binários (com valores um e zero), camadas F1 (camada de comparação) e F2 (camada de reconhecimento). Cada neurônio em F1 é conectado a

todos os neurônios em F2 através da memória de longo termo W^f (LTM) e vice-versa através da resposta LTM (W^b). Os outros módulos são ganhos 1 e 2 ($G1$ e $G2$) e um módulo de reinício (figura 3.8) [34].




Figura 3.8 - A estrutura da rede ART [34]

Cada neurônio na camada de comparação recebe 3 entradas: um componente de um padrão entrada, um componente de padrão de retorno e um ganho $G1$. Um neurônio dá saída 1 se e somente se pelo menos 2 dessas entradas são altas (A chamada “regra de dois em três”).

Os neurônios na camada de reconhecimento computam o produto interno de seus pesos e dos padrões internos das conexões.

O neurônio vencedor então, inibe todos os outros através da chamada inibição lateral.

O ganho 2 é o "ou" lógico de todos os elementos no padrão de entrada x .

O ganho 1 iguala o ganho 2, exceto quando o padrão de retorno de F2 contém algum "um". Então, ele é forçado a "zero".

Finalmente, o sinal de reinício é enviado ao neurônio ativo em F2 se o vetor entrada x e a saída de F1 diferem por mais do que um nível determinado. Essa diferença entre o novo padrão e o padrão anterior é conhecido por "parâmetro de vigilância".

Efetivamente, as pesquisas sobre redes neurais voltaram a um estado de euforia na década de 80, principalmente após a divulgação dos estudos de Hopfield (1982) [42], cujo sistema trabalhava com uma rede associativa em linha transversal. Ele introduziu em redes neurais o conceito de mínima energia. Segundo as redes de Hopfield, os elementos processadores aprendiam com uma função de mínimo de energia.

Nas redes de Hopfield, a saída de todos os elementos processadores está ligada à entrada de todos os demais, exceto de si próprio. (figura 3.9) .

A chamada Máquina de Boltzmann, de Hinton, Ackey e Sejnowsky (1985) [3,34], usa o conceito de energia de Hopfield e simula um sistema termodinâmico, sujeito às leis da termodinâmica. A função que simula a temperatura é inicializada com valores altos, e, de acordo com a regra de aprendizado desse paradigma, a função de energia é modificada, de modo que a temperatura tenda a zero.

Outros tipos de redes pesquisados recentemente [33], praticamente em desenvolvimento, são as Redes Espaço-Temporais, que tratam dados e saídas que são funções do tempo, as Redes




Figura 3.9 - A rede de Hopfield [33]

Estocásticas, que possuem um componente probabilístico, que atua de acordo com determinada distribuição, e as Redes Hierárquicas, cujos elementos processadores são conectados somente a um conjunto restrito de elementos de outras camadas, cujo exemplo mais conhecido é o Neocognitron, de Fukushima.

Finalmente, a implementação de redes neurais, pode ser dividida em 3 categorias: [34]

1. Simulação em “software”;
2. Emulação ;
3. Implementação em “hardware”.

Simulação é quando descreve-se pacotes de “softwares” que podem rodar numa variedade de máquinas, por exemplo, o Pygmalion, NeuralWare, Nestor, etc. Implementação em máquinas multi-processadoras de finalidades diversas, como a Connection Machine, ou a Warp, por exemplo, pode ser entendido como emulação.

A implementação em hardware é reservada para neuro-chips ou similares.

Quanto a esses, em geral, suas aplicações no mundo real dependem do advento de um hardware bastante poderoso para sua perfeita implementação. [33]

Geralmente os neuro-computadores são acoplados como co-processadores a um computador programável tradicional.

As pesquisas atuais na área da neurocomputação, mormente após a década de 80, vêm crescendo substancialmente, encontrando campos de aplicação em atividades diversas e interdisciplinares, como na química [49], na meteorologia, na medicina, na lingüística [44], enfim, havendo possibilidades de uso ilimitadas em todas as atividades do ser humano, muitas delas com aplicações práticas relevantes.

É importante ressaltar, no entanto, que todo o conhecimento até hoje adquirido em computação neural representa uma parcela ínfima do potencial de descobertas e conhecimentos na área, o que reflete o relativo pouco conhecimento que se tem dos sistemas nervosos e neurológicos dos seres vivos.

3.5. REDE NEURAL EM BACK-PROPAGATION

Deve-se principalmente a Rumelhart a rede em “back-propagation”, o mais popular paradigma entre os diversos conhecidos. Igualmente, as aplicações mais simples e conhecidas das redes neurais na usinagem dos metais, principalmente no monitoramento via emissões acústicas, usam a arquitetura em back-propagation.

Por isso, apresenta-se nesse item os fundamentos principais desse paradigma, que é baseado no processamento paralelo distribuído (PDP) [45] (Rumelhart e McLelland).

3.5.1. TOPOLOGIA DA REDE BACK-PROPAGATION

Na rede back-propagation, existem no mínimo 3 camadas: as camadas de entrada e de saída, que são o contato com o meio ambiente e pelo menos 1 camada escondida. Cada camada é integralmente interligada à seguinte, como pode se ver na figura 3.10 .




Figura 3.10 - A topologia da rede back-propagation [33]

O elemento processador é tal como na figura 3.1, e se comporta como no item 3.2.1.

3.5.2. REGRA DE APRENDIZADO NA REDE "BACK-PROPAGATION"

A regra delta é utilizada em redes de "back-propagation".

O cálculo dos erros é realizado como abaixo [20]:

$$E_k = f'(I_k) * (Y_k - Y_k'), \text{ sendo:}$$

f é uma função contínua e derivável em todo o domínio, como a sigmóide, a tangente hiperbólica ou a função seno.

k é o elemento k da camada de saída

I é a soma ponderada dos valores de entrada

Y e Y' são os valores real e desejado da saída, respectivamente.

Para o elemento i da camada intermediária j , o erro é calculado em função do erro na camada imediatamente posterior, pela fórmula:

$$E_{i,j} = f'(I_{i,j}) \sum (E_{k,j+1} * W_{i,k,j+1})$$

sendo:

$E_{(j+1)}$ o erro calculado para os elementos da camada $j+1$ e $W_{i,j+1}$, os pesos das conexões que partem do elemento i para esta (figura 3.10).

Os erros, calculados como acima, fazem com que os pesos dos elementos da camada j sejam atualizados de acordo com a seguinte fórmula:

$$W_{i,j+1} - W_{i,j} = C * E_{i,j} * X_{i,j}$$

onde C é o coeficiente de aprendizado e $X_{i,j}$ é o conjunto de valores de entrada para o elemento.

Para tornar o cálculo iterativo, pode-se acrescentar o termo chamado "momento", conforme:

$$W(i,j) = C * E(i,j) * X(i,j-1) + M * W_{ant}.$$

De modo resumido, o algoritmo da regra delta ajusta os pesos de acordo com o vetor de entrada dado e o vetor de saída desejado. Aos pesos da rede "back-propagation" são aleatoriamente atribuídos valores baixos, de preferência.

As ativações são propagadas no sentido da camada de entrada para a(s) camada(s) intermediária(s) e a partir da última camada escondida, em direção à camada de saída, através das funções de transferência mencionadas (sigmóide, por exemplo).

Os erros são calculados na camada de saída (entenda-se erro como a diferença entre o valor de saída real e o valor de saída desejado). O mesmo ocorre entre as camadas intermediárias. A taxa de erro é propagada no sentido inverso, ocorrendo modificação de pesos, primeiro entre as camadas intermediárias e a camada de saída, depois entre a camada de entrada e as camadas intermediárias.

Assim, novamente as ativações são propagadas, sempre no sentido da camada de entrada para a camada de saída e os erros propagados no sentido inverso, com reajuste dos pesos, até que haja a convergência suficiente para que as saídas reais sejam próximas às saídas desejadas.

Uma extensão da regra delta é a regra delta cumulativa, onde os erros são calculados e guardados durante uma quantidade determinada de exemplos e só então os pesos são atualizados. Isso aumenta a rapidez do processamento, ou seja, há maior velocidade de convergência no cálculo iterativo.

Apesar do sucesso do algoritmo "back-propagation", o algoritmo mais usado de todos os aplicáveis em redes neurais, há

algumas limitações que, no momento, não garantem seu uso universal.[3,34], sendo que existem alguns problemas que podem ocorrer na fase de execução da rede.

O maior problema é o período longo e incerto de treinamentos. Para problemas complexos, pode-se requerir dias ou semanas para se treinar a rede e ainda assim não se efetivar o treinamento total. As principais fontes de problemas na rede “back-propagation” são oriundos de: [3]

a) Paralisia da rede.

Quando a rede está em aprendizado, os pesos podem ser ajustados a uma faixa de valores muito largos. Isso pode forçar todos (ou a maioria) de neurônios a operar com valores largos de saída. Desde que o erro enviado de volta para o treinamento é proporcional à saída, o processo de treinamento pode ter uma virtual saturação.

b) Mínimo local.

A rede ajusta os pesos em direção do mínimo. A superfície do erro de uma rede complexa é altamente cheia de picos, vales, dobras e pontos de inflexão em um espaço multi-dimensional. A rede pode ser apanhada em um local de mínimo (um vale profundo) onde há somente mínimos profundos aos arredores. Para o limitado ponto de vista da rede, todas as direções estão acima e não há meio de escapar.

c) Convergência.

As redes são projetadas para ajustamentos de pesos infinitesimalmente pequenos. Isso é ainda impraticável na execução da rede, pois se requer tempo de treinamento infinito. Para acertar os parâmetros de treinamento da rede, portanto, é necessário um pouco de experiência, para se requerer convergência adequada,

evitando que se resultem instabilidades temporárias, mínimos locais e paralisia da rede.

Deve-se mencionar que para todos os problemas citados anteriormente, segundo Wasserman [3], há diversos métodos que podem ser tentados para evitar os problemas, sendo alguns deles ainda em caráter experimental.

3.6. APLICAÇÕES DE REDES NEURAI

A neurocomputação como um dos ramos mais proeminentes da inteligência artificial tem aplicação em praticamente todas as atividades do ser humano. A cada dia que passa, novas aplicações das redes neurais são encontradas, muitas delas ultrapassando a fronteira de interesse científico e acadêmico, encontrando lugar em usos práticos da vida real.

Por serem inúmeras as utilizações das redes neurais, nesse item são citadas primeiro algumas das aplicações elementares, de trabalhos clássicos feitos pelos pesquisadores pioneiros da neurocomputação, que abriram caminhos e horizontes para pesquisas futuras. Por fim, apresenta-se alguns trabalhos significativos dentro da engenharia mecânica, em particular de usinagem dos metais.

A) Meteorologia.

Nos anos 60, utilizando-se redes Multiple Adaline, Widrow desenvolveu uma rede que previa o tempo de maneira bastante satisfatória. Três Adalines na camada escondida foram conectados aos buffers de saída [34].

B) Hierarquização de espécies animais e vegetais.

Uma contribuição de Kohonen, com seus mapas auto-organizáveis é a classificação de espécies de flores, a partir das dimensões de pétalas e sépalas [34].

C) Processamento de linguagem natural.

Um sistema calcado em redes neurais, desenvolvido por Rumelhart e McLelland foi capaz de aprender o passado simples de alguns verbos ingleses. Após o aperfeiçoamento do sistema, ao se apresentar verbos nunca antes conhecidos ou novos, devido à alta capacidade de generalização das redes neurais, uma boa previsão era fornecida [34,47].

D) Reconhecimento de padrões visuais.

O reconhecimento de padrões visuais compreende [34,41]:

- 1) Reconhecimento - a classificação dos dados de entrada em uma quantidade de casos possíveis;

- 2) Informação geométrica sobre o sistema, o qual é importante para sistemas autônomos;

- 3) Compressão de imagens para armazenamento e transmissão;

Como citado anteriormente, talvez o maior e melhor exemplo seja o Neocognitron.

E) Filtragem de ruídos.

Na medicina, uma importante aplicação foi o desenvolvimento de redes neurais usados para remover ruídos de eletrocardiogramas [33].

F) Robótica.

No campo da robótica, essas redes são usadas para direcionar um manipulador, que é a forma mais importante de um robô industrial [34], para agarrar objetos, baseados em movimentos

dependentes de dados sensoriais. Outras aplicações incluem as esteiras e veículos auto guiados (AGV).

3.6.1) EXEMPLOS DE APLICAÇÕES DE REDES NEURAI NA USINAGEM

Teshima et ali [46] apresentaram um trabalho de estimativa do resto de vida da ferramenta de corte no torneamento a partir de imagens, via redes neurais. Os dados são obtidos pelo processamento de dados de imagens após o corte, e então a aplicabilidade da ferramenta para o próximo processo de corte sob diferentes parâmetros de corte pode ser predito. Usou-se uma rede neural "back-propagation", cujo vetor de entrada teve 253 elementos processadores (110 e 138 pontos relativos à cor da ferramenta de metal duro , respectivamente nas superfícies de flanco e de saída) e mais 5 entradas correspondendo a condições de corte e um vetor de saída de 6 elementos na camada de saída, representando dados relativos ao grau de desgaste na ferramenta e estimativas de resto de vida da ferramenta. Comparações entre resultados experimentais e saídas do sistema de redes neurais nas mesmas condições apresentaram resultados semelhantes, comprovando a eficácia do sistema. Uma próxima etapa do trabalho é sua aplicação em ambientes reais FMS.

Jammu, Danai e Malkin [47] propuseram um novo sistema de redes neurais não supervisionado (os mais conhecidos dessa categoria são as redes de Kohonen e as redes ART). Esse método detecta a quebra da ferramenta usando sensores múltiplos. Somente necessita definir o vetor protótipo para a categoria "normal", por isso conhecida como SCBC (Single-Category-Based-Classfier). Esta rede detecta a anormalidade através da comparação de cada

grupo de medidas contra os valores protótipos (categoria normal). Assume-se que a quebra da ferramenta ocorre quando as medidas são suficientemente diferentes de seus protótipos normais. A diferença entre as mesmas na SCBC é determinada pela distância Euclideana das médias em relação aos protótipos.

Esse modelo foi usado em torneamento em testes extensivos que produziram 6 casos de quebra da ferramenta.

Os resultados mostraram que a SCBC foi a única rede não supervisionada capaz de detectar todos os casos de quebra, em cada um dos 6 experimentos, ou com a sequência de testes diferentes, comparando com a mesma experimentação usando as redes de Kohonen e a ART-2. Os autores concluíram que o melhor resultado da rede SCBC se deveu a suas melhores técnicas de supressão de ruídos.

Nos processos de retificação, o processo de tomada de decisões baseia-se muito na experiência dos operadores, pois há muitos fatores que afetam o processo de retificação. Sakakura e Inasaki [48] investigaram os processos de tomada de decisão de operadores e enfatizaram a importância da memória associativa. Baseado nesse fato, eles propuseram uma rede neural híbrida que imitava o processo de decisão humano. Esse modelo foi aplicado ao processo de tomada de decisões das condições de dressagem.

O sistema consistiu em uma estrutura multi-estágios, composta de 2 tipos de redes. Um deles é uma rede "back-propagation" a qual recebeu a dureza da superfície do material usinado como entrada e fornecia como saída os candidatos às condições de dressagem (avanço na dressagem e profundidade de corte de dressagem). A outra é a rede "Brain-State-in-a-Box" (BSB). As entradas iniciais na rede BSB foram a dureza requerida

da superfície (entrada da rede “back-propagation”) e as condições de dressagem correspondentes à saída da rede back-propagation.

Através de muitos exemplos de retificação cilíndrica, sob diversas condições, verificou-se que:

A rede “back-propagation” fornecia alguns candidatos promissores às melhores condições de dressagem e a rede BSB selecionava a melhor combinação entre os mesmos, levando em conta a correlação entre 3 fatores: dureza da superfície, profundidade de corte da dressagem e avanço na dressagem.

Esse processo é muito similar às atitudes humanas, pois o funcionamento é o mesmo que o feito pelo operador, o qual, através de sua própria experiência evoca a memória associativa e seleciona o melhor procedimento.

A efetividade do modelo proposto foi confirmada por simulações no computador. A vantagem do mesmo é o alto grau de flexibilidade e pode ser aplicado a vários processos modificando os dados de aprendizagem.

Na área de monitoramento das condições de ferramenta usando redes neurais, a contribuição de Dornfeld [35,36,37] não pode deixar de ser citado. Entre suas várias contribuições, pode-se citar o projeto e implementação de sistema de redes neurais combinando as saídas de diversos sensores para monitoramento de desgaste da ferramenta de torneamento. Parâmetros como coeficientes de séries temporais e amplitudes de espectro do sinal de força foram usadas como entradas à rede. O objetivo descrito foi estender o campo de condições de usinagem acima do qual o sistema opera com sucesso.

Com o desenvolvimento de pesquisas sobre sensores, tornou-se consenso que a performance de múltiplos sensores é muito mais eficaz do que informação de um único sensor. Então, a

fusão de sensores (sensor fusion) é entendida como a estratégia de integração das informações oriundas de uma variedade de sensores com a expectativa de que isso aumentará a acuracidade e resolva ambigüidades no conhecimento do sistema. (Chiu et ali (1986)) [50].

Um dos experimentos de Dornfeld consistiu no emprego de uma rede “back-propagation” para integrar informações de diversos sensores (a partir de emissão acústica, força e corrente do motor do fuso). Esses sinais dos sensores foram processados usando modelos de séries autoregressivas (AR) ou a Transformada de Fourier (FFT)). Esses sinais serviam de entrada para a rede, que classificou a ferramenta em adequada ou desgastada. (De fato, até hoje, a melhor função para as redes neurais conhecidas parece ser classificar atributos, por exemplo em bom ou ruim, permitindo a partir da classificação, a tomada de decisões cabível).

Duas séries de experimentos de torneamento foram realizadas, uma para servir de base de dados para o treinamento do sistema, e outra para a validação do sistema.

As conclusões mais notáveis foram:

1) A combinação RMS E.A. + Força deu resultados melhores (95% de acerto), contra 73% da combinação Força + Corrente e 62% da combinação RMS E.A. + corrente.

2) O número de camadas escondidas variando de 2 até 6 mostrou maior percentagem de acertos de até 96% e a partir da sexta até a décima camada escondida, a performance foi abaixando consideravelmente (até 91%). (Rever tabela 3.1).

3) O número crescente de camadas acrescenta uma perda de eficácia e considerável aumento de tempo no processamento.

4) O sistema de detecção de desgaste da ferramenta é insensível a mudanças nas condições de corte, podendo operar sob

uma larga faixa de condições, até mesmo quando treinado em apenas uma única condição de corte.

CAPÍTULO 4

EQUIPAMENTOS, MATERIAIS E PROCEDIMENTOS EXPERIMENTAIS

4.1 - EQUIPAMENTOS UTILIZADOS E MONTAGEM DO SISTEMA

O esquema da montagem do sistema utilizado para o monitoramento do desgaste da ferramenta via vibrações pode ser visto na figura 4.1.




Figura 4.1 - Montagem do sistema de monitoramento do desgaste da ferramenta

Foi utilizado um torno CNC ROMI com as seguintes características:

- potência : 30 HP
- Motor principal e servo motores de avanço da ferramenta acionados por corrente contínua
- Rotação máxima : 3000 rpm.

As ferramentas de corte utilizadas foram pastilhas de metal duro TNMG 160408-61 da Sandvik (típica para operações de acabamento e desbaste leve), com recobrimento GC 435 (classe ISO P35).

As características físicas dessa ferramenta são: [51]

- Alta tenacidade e baixa resistência ao desgaste;
- Típico para desbastes leves e médios de aços. Pode ser utilizado em condições desfavoráveis;
- Velocidades de corte e avanços médios;
- Produção de cavacos longos e dúteis (cavaco contínuo);
- Dureza elevada (à temperatura ambiente e também em elevadas temperaturas), alta tenacidade (resistência à ruptura transversal) e boa estabilidade química a altas temperaturas.

A cobertura do metal duro GC 435 é formada por triplo revestimento de TiC, Al_2O_3 e TiN (figura 4.2), cujas características são:

- Espessura total do revestimento: 8 μm ;
- Adequado para operações de torneamento sob condições desfavoráveis;
- A camada mais interior é a TiC, cujas características são: excelente resistência ao desgaste por abrasão, promove a adesão das camadas de cobertura com o metal duro ao núcleo,

elevada dureza (cerca de 5000 HV contra aproximadamente 1800 HV do núcleo de metal duro), baixa soldagem com o material da peça e baixo coeficiente de dilatação térmica [8].

- Al_2O_3 é a camada intermediária, que garante a estabilidade térmica em temperaturas elevadas, alta resistência ao desgaste por abrasão e aos ataques químicos [8].

- TiN é a camada mais externa desse grupo de pastilhas. Reduz o coeficiente de atrito entre a pastilha e o cavaco e é quimicamente mais estável que o TiC (menor tendência à difusão com aços)[8].




Figura 4.2 - as 3 camadas da cobertura da ferramenta utilizada

O porta-ferramentas utilizado foi o PTGNR 2525 M16 da Sandvik.

Os acelerômetros piezoelétricos, como explicado no capítulo 2, são sensores que medem a vibração instantânea do material em usinagem na forma de voltagem.

Utilizou-se um tipo de acelerômetro Kistler, cujas características são as seguintes, de acordo com o fabricante:

- Campo de medição: $\pm 500 \text{ g}$ ($g = 9,81 \text{ m/s}^2$)
- Sensibilidade = $10,73 \text{ mV/g}$
- Sensibilidade cruzada = $3,3 \%$
- Frequência de ressonância = 50 kHz
- Faixa de frequência até 8000 Hz
- Temperatura de operação de -55°C a 120°C .

Colocou-se 2 acelerômetros no porta-ferramentas, de forma que foram observadas as 2 direções que interessam à medição de vibrações: direção de avanço e direção de corte da ferramenta.

O porta-ferramentas foi escolhido como local de colocação dos acelerômetros (figura 4.3), pois a vibração que interessa ao monitoramento do desgaste da ferramenta é devido às interfaces ferramenta-peça e cavaco-ferramenta. Assim o sinal captado é adequado, pois os acelerômetros estão instalados próximos à região de corte.

Os acopladores ou “couplers” permitem a leitura dos dados dos acelerômetros. Suas funções são:

- Fornecer uma corrente de excitação constante ao acelerômetro;
- Servir de elo de ligação do sinal dos acelerômetros com o equipamento de leitura do sinal.

Nos ensaios deste trabalho foi usado um acoplador Kistler “Piezotron Coupler”.




Figura 4.3 - Localização dos acelerômetros no porta-ferramentas.

O equipamento de leitura do sinal é a placa de conversão A/D, que permite que o sinal de vibração do acelerômetro (do tipo analógico) seja convertido para o tipo digital, que é o tipo que permite a leitura pelo computador. Ou seja, a voltagem é transformada em caracteres que podem ser lidos e processados pela unidade de processamento central do computador.

Os sinais digitalizados são adquiridos por um software específico de aquisição de dados (AQUIS), instalado na memória do microcomputador PC-AT 286 utilizado.

Os dados, depois de coletados, são armazenados em unidades de discos flexíveis, para posteriormente serem analisados.

Como a frequência dos sinais amostrados desejado pode chegar a 8000 Hz (máxima frequência do sensor), amostrou-se dois canais (com 1024 pontos por canal), com amostragem realizada a 16000 Hz, correspondente a 62.5 μ s de tempo de amostragem.

Utilizou-se um rugosímetro de contato Mitutoyo "Surftest 211" para a medição das rugosidades (R_a e $R_{máx}$) da superfície da peça. Mediu-se a rugosidade em três pontos distintos da peça, distanciados de aproximadamente 120 graus entre si. O valor considerado na análise dos resultados é uma média desses três pontos.

4.2 - MATERIAL USINADO

Utilizou-se 38 corpos de prova de aço ABNT 4340 (aço molibdênio ao cromo-níquel), como mostrado na figura 4.4, com os seguintes limites em sua composição química, segundo a NB-82 da ABNT:

- C = 0,38 a 0,43%
- Mn = 0,60 a 0,80%
- Ni = 1,65 a 2,00%
- Cr = 0,70 a 0,90%
- Mo = 0,20 a 0,30%

De acordo com o fabricante, as características mecânicas desse aço são [32]:

- Limite de resistência: 95 kgf/mm²
- Dureza: 250 HB
- Alongamento: 28%
- Limite de escoamento: 85 kgf/mm²

- Estricção: 65%




Figura 4.4 - Dimensões do corpo de prova utilizado (em mm)
(Aço SAE 4340)

4.3 - METODOLOGIA DOS ENSAIOS DE USINAGEM

O roteiro da metodologia usada nesses ensaios é como se segue:

Inicialmente, faz-se o zeramento do sinal de saída do acoplador (possibilitado pelo mesmo), com o torno desligado.

O programa de aquisição de sinais somente é acionado alguns segundos após o corte ter sido iniciado.

Com uma aresta de corte nova da ferramenta, retira-se material de cada peça correspondente a 5 passadas da ferramenta na

mesma, sendo que cada passada ($a_p = 1 \text{ mm}$) gera um arquivo de sinal RMS na direção de avanço e outro na direção de corte. A seguir, a peça é retirada, as rugosidades R_a e $R_{\text{máx}}$ são medidas no rugosímetro e outra peça é colocada para usinagem até que o corpo de prova atinja uma rugosidade R_a no mínimo 3 vezes maior que a do primeiro corpo a ser usinado. Ao chegar-se ao fim do ensaio, troca-se a pastilha e repete-se os procedimentos citados, com novas condições de usinagem.

Dessa forma foram geradas algumas centenas de arquivos de sinais correspondentes a cada passada (precisou-se de 14 disquetes de 5,25 pol e densidade simples para arquivar exclusivamente esses sinais).

Em suma, os sinais de aceleração instantânea em forma de voltagem são fornecidos como saída do programa de aquisição de dados e as rugosidades foram periodicamente medidas e anotadas. Esses parâmetros foram analisados e no capítulo 5 serão mostradas as análises e conclusões pertinentes.

Esses procedimentos foram, portanto, repetidos em todo o ensaio de usinagem, que compreendeu onze variações de avanço e velocidades de corte, conforme mostra a tabela 4.1.

A faixa de velocidades de corte e avanços correspondem a condições típicas de usinagem em acabamento.

Como se vê na figura 4.5, a ordem de realização dos ensaios foi aleatória.

Número do ensaio	Avanço (mm/volta)	Velocidade de corte (m/min)	Profundidade de usinagem (mm)
1	0,20	250	1,0
2	0,15	300	1,0
3	0,10	350	1,0
4	0,15	325	1,0
5	0,20	350	1,0
6	0,10	300	1,0
7	0,20	300	1,0
8	0,15	275	1,0
9	0,15	250	1,0
10	0,15	350	1,0
11	0,10	250	1,0

Tabela 4.1 - Condições de usinagem para o ensaio de desgaste




Figura 4.5 - Ordem de execução dos ensaios (para $a_p = 1,0$ mm)

4.4 - EXECUÇÃO DAS REDES NEURAIS

Para a execução das redes neurais, utilizou-se um software específico de redes neurais artificiais, o ANSim, versão 2.02, instalado em um microcomputador PC 486.

As características desse software são [52] :

- O ambiente de trabalho do ANSim é um computador compatível com um padrão IBM PC/AT com configuração mínima de: sistema compatível com processador 80286, 640 kB de memória RAM, 1,2 MB de drive de disco flexível, disco rígido, mouse e monitor padrão EGA;

- Ambientes de trabalhos com configurações superiores aumentam drasticamente a performance do software;

- A velocidade de processamento do ANSim depende da configuração do hardware, paradigmas da rede, seleção de parâmetros de rede e opções de interface utilizadas. Por exemplo, em estações de trabalho do tipo "Sigma Neurocomputer", altamente especializado na neurocomputação, o ANSim processou redes "back-propagation" com velocidade de até 20000 conexões por segundo no modo de treinamento e até 45000 conexões por segundo no modo de validação ("recall").

- O menu principal se compõe de 4 itens: "file menu", "display menu", "run menu" e "network menu". O "file menu" serve para iniciar, carregar, salvar, fechar uma rede e para fazer conversões de arquivos textos. O "display menu" permite mostrar estados de ativação, pesos e "status" da rede instantâneos durante o processamento. O "run menu" permite que a rede execute os arquivos de treinamento e arquivos "recall", através de dados fornecidos pelo usuário para esses fins. Os arquivos são lidos pela rede neural na forma de matrizes de vetores numéricos que podem ser gerados pelo usuário através de editores de texto simples, como o do Windows ou do próprio sistema DOS e depois convertidos em arquivos que possam ser lidos pela rede. O "network menu" permite estipular e modificar os parâmetros da rede, estabelecer o número de camadas e seus tamanhos, editar e interromper temporária ou definitivamente a execução da rede.

- Em resumo, o ANSim possibilita ao usuário configurar qualquer número de redes, dirigir cada rede com uma sequência de treinamentos ou dados de entrada, monitorar e capturar a resposta da rede (saída) e salvar sua configuração (treinada ou não) para posterior uso.

Nesse trabalho, executou-se as seguintes fases da rede neural:

a) de treinamento: a partir de dados reais oriundos do ensaio de usinagem do aço 4340, obteve-se valores que serviram de entrada e saída para a rede neural "back-propagation". Ou seja, através de um arquivo do editor de texto, ensinou-se os valores de entrada e correspondentes valores de saída à rede, que estabeleceu conexões internas e critérios próprios de avaliação e julgamento.

b) fase de validação ("recall"): após a fase de treinamento da rede, através do redator de textos, forneceu-se apenas os valores de dados da entrada. A própria rede neural, tendo anteriormente "aprendido", forneceu os valores de saída, isto é, a rede neural forneceu um conjunto de saídas próprias em resposta aos dados de entrada fornecidos, pois uma vez treinada a rede, ela pode fornecer valores de saída para situações de entrada nunca antes ensinadas.

Como será visto no capítulo seguinte, na fase de treinamento, os parâmetros de entrada da rede foram: velocidade de corte, avanço, comprimento de corte, sinal RMS na direção de avanço e sinal RMS na direção de corte. Numa primeira etapa de utilização da rede, os parâmetros de saída ensinados foram as rugosidades R_a e $R_{\max}$ e o "Status" da ferramenta. Numa segunda etapa de utilização da rede, o parâmetro de saída foi somente o "Status da ferramenta".

Na fase de validação ("recall"), o mesmo conjunto de parâmetros de entrada foi fornecido e os parâmetros de saída eram fornecidos pela rede.

Os parâmetros de sete dos onze ensaios realizados (ensaios números 1 a 7) foram utilizados na fase de treinamento e os parâmetros dos 4 ensaios restantes (ensaios números 8 a 11) foram utilizados na fase de validação.

Cada ensaio forneceu de 12 a 51 conjuntos de dados de entrada e saída para a fase de treinamento da rede, totalizando 173 conjuntos de dados.

Para que a condição de desgaste da ferramenta pudesse ser colocada como parâmetro de saída da rede (parâmetro "Status"), todo o tempo de corte de uma aresta foi dividido em 4 etapas, que receberam números de 1 a 4. Tais etapas foram:

Status 1 - estágio inicial de desgaste da ferramenta

Status 2 - estágio intermediário de desgaste da ferramenta

Status 3 - estágio de crescimento rápido do desgaste

Status 4 - estágio de deterioração acentuada da ferramenta

A definição do momento de passagem de um "Status" para outro será melhor explicado no capítulo 5 (quando já se estiver de posse das curvas com os resultados). Aqui porém deve-se citar que o "Status" em que a ferramenta deve ser substituída é o "Status" 3, onde ainda não se atingiu a completa deterioração da aresta (mas, como o processo de desgaste é bem rápido nesta fase, esta deterioração vai ser logo atingida) e, portanto, ainda não se ultrapassou um valor limite de rugosidade da peça.

CAPÍTULO 5

RESULTADOS E DISCUSSÕES

5.1. ENSAIO DE VIDA DA FERRAMENTA VARIANDO-SE AS CONDIÇÕES DE USINAGEM

Foram realizados ensaios de torneamento até o fim da vida da ferramenta, segundo o critério adotado.

Para uma mesma profundidade de usinagem, variou-se a velocidade de corte e o avanço. Esses dois últimos têm uma influência mais significativa no processo de desgaste das ferramentas do que a profundidade de usinagem.

Segundo o consenso da literatura consultada, a profundidade de usinagem também não tem influência marcante na rugosidade. Ensaios que comprovam essa afirmação podem ser vistos no trabalho de Bonifácio e Diniz [32].

Desta forma, neste trabalho observou-se apenas a influência do avanço e da velocidade de corte na amplitude de vibração da ferramenta de torneamento (RMS do sinal que sai do acelerômetro), comparando-a sempre com a rugosidade superficial da peça, tudo isso à medida que o tempo de corte passava e a ferramenta se desgastava.

Alguns dos parâmetros testados e os respectivos resultados obtidos através dos diversos ensaios podem ser vistos nos gráficos das figuras 5.1 a 5.8, que mostram respectivamente:

Figura 5.1 - Rugosidade (R_a) x Comprimento de corte (v_c variando);

Figura 5.2 - Rugosidade ($R_{m\acute{a}x}$) x Comprimento de corte (v_c variando);

Figura 5.3 - Vibração na direção de avanço (RMS) x Comprimento de corte (v_c variando);

Figura 5.4 - Vibração na direção de corte (RMS) x Comprimento de corte (v_c variando);

Figura 5.5 - Rugosidade (R_a) x Comprimento de corte (f variando);

Figura 5.6 - Rugosidade ($R_{m\acute{a}x}$) x Comprimento de corte (f variando);

Figura 5.7 - Vibração na direção de avanço (RMS) x Comprimento de corte (f variando);

Figura 5.8 - Vibração na direção de corte (RMS) x Comprimento de corte (f variando).

O gráfico da figura 5.1 apresenta o valor da rugosidade de acordo com o crescimento do comprimento de corte em metros, para cinco velocidades de corte distintos e único avanço (vale lembrar que a ordem real dos ensaios de usinagem foi aleatória, ou seja, foram variados aleatoriamente a velocidade de corte e o avanço entre um ensaio e outro).

Algumas conclusões podem ser observadas através desse gráfico:

- A rugosidade não foi influenciada diretamente pela velocidade de corte, isto é, não se apresentou uma relação linearmente direta ou inversa entre o aumento da velocidade e da rugosidade. Pode-se ver que, no início da vida da ferramenta, os valores de rugosidade são muito próximos para todas as velocidades de corte testadas.

- A velocidade de corte teve influência na vida da ferramenta, como era de se esperar, de acordo com a literatura. De fato, quanto maior a v_c , tanto mais precoce se atingiu o fim da vida da ferramenta. (Aqui se estabeleceu que o fim da vida aconteceu quando a rugosidade cresce abruptamente). Porém, duas velocidades de corte fugiram a esta regra: a vida da ferramenta com $v_c = 325$ m/min se apresentou menor do que com $v_c = 350$ m/min.

- As curvas permanecem praticamente constantes até que crescem abruptamente no fim da vida, sofrendo um abrupto aumento em seus valores. Este comportamento ocorre devido ao fato de que, depois de algum tempo de corte, as camadas de cobertura da ferramenta são consumidas pelo desgaste e a ferramenta começa a realizar o corte com seu substrato, o que aumenta substancialmente a taxa de desgaste (o substrato é bem menos resistente ao desgaste que as coberturas) e, conseqüentemente, a rugosidade da peça (este nível de desgaste da ferramenta será aqui chamado de desgaste crítico).

- Esse abrupto aumento se verifica também nos gráficos seguintes, figuras 5.2 a 5.4, que relacionam ao comprimento de corte a rugosidade máxima, o RMS da vibração na direção de avanço e o RMS da vibração na direção de corte, respectivamente. Para todos os outros ensaios, nas diversas condições descritas no capítulo anterior, tal tendência se verificou a partir do momento em que a ferramenta atinge seu desgaste crítico;

- Comparativamente, pode-se dizer que, com pequenas variações, o ponto em que tanto os valores RMS da vibração quanto as rugosidades crescem abruptamente são semelhantes. (Isso será mostrado e comentado mais adiante, tabela 5.1);




Figura 5.1 - Rugosidade (Ra) x Comprimento de corte (vc variando)




Figura 5.2 - Rugosidade (Rmáx) x Comprimento de corte (vc variando)

Dos gráficos das figuras 5.3 e 5.4, as seguintes observações podem ser feitas:

- Existe uma leve tendência do crescimento do sinal RMS com o aumento da velocidade de corte, isto é, quanto maiores as velocidades de corte (mantido o avanço), maior é o valor da vibração no início da vida da ferramenta, tanto na direção de avanço, quanto na direção de corte. Isto não está de acordo com o que afirma a literatura (ver capítulo 2). Parece que este pequeno aumento da vibração ocorrido tem pouco a ver com a formação da aresta postiça de corte ou com o mecanismo de formação do cavaco (como atesta a literatura), mas sim com a estabilidade do sistema Máquina-Ferramenta-Dispositivo-Peça.

Inicialmente o sinal tem ligeira queda, vindo a estabilizar-se e manter-se praticamente constante até determinado momento, a partir do qual ocorre o seu abrupto aumento. Novamente esse crescimento acentuado do sinal pode ser explicado como anteriormente, no que se refere ao desgaste de ferramentas recobertas.

Dos gráficos das figuras 5.5 a 5.8, variação do avanço, depreende-se que:

- O comportamento tanto da rugosidade (R_a e $R_{máx}$), quanto da vibração (RMS nas direções de avanço e corte) com o comprimento de corte foi muito semelhante àquele acontecido quando se variou a velocidade de corte, isto é, com pequenas variações todos estes valores mantiveram-se constantes, até que, em determinado momento, tanto a rugosidade quanto a vibração cresceram abruptamente, devido ao aumento abrupto dos valores de desgaste. Isto comprova a eficiência da utilização dos sinais de vibração para o monitoramento do fim da vida da ferramenta de torneamento de acabamento.

- O avanço tem influência na rugosidade máxima particularmente quando o avanço passa de $f = 0.15$ mm/volta a 0.20 mm/volta. Teoricamente era de se esperar tal comportamento, à luz da expressão $R_{\text{máx}} = f^2 / 8r$, que mostra os efeitos de contribuição geométrica do avanço e do raio de ponta na rugosidade máxima. A pequena variação de $R_{\text{máx}}$ quando se passa de $f = 0,10$ para $f = 0,15$ mm/volta (bem menor do que a expressão acima prevê) é devido aos altos valores da pressão específica de corte (K_s) para pequenos valores de avanço. Quando f passou de 0,10 para 0,15 mm/volta, a diminuição de K_s , devido a uma deformação mais fácil do cavaco, que tende a diminuir a rugosidade, contrabalanceou o aumento da contribuição geométrica do avanço na rugosidade e, assim, esta permaneceu praticamente constante.

- À medida que o avanço cresce, a vida da ferramenta decresce, mas numa escala menor do que quando se variou a velocidade de corte. Assim, quando o avanço passou de 0,15 para 0,20 mm/volta (33% de variação), a vida da ferramenta (aqui está se entendendo vida da ferramenta como o momento em que tanto a rugosidade, quanto a vibração cresceram abruptamente) caiu de 1700 para 1530m (10% de variação). No caso da velocidade de corte, quando v_c passou de 250 para 300 m/min (20% de variação), a vida caiu de 2750m para 1700m (38% de variação). Este comportamento está de acordo com a literatura.




Figura 5.3 - Vibração na direção de avanço (RMS) x Comprimento de corte (v_c variando)




Figura 5.4 - Vibração na direção de corte (RMS) x Comprimento de corte (v_c variando)




Figura 5.5 - Rugosidade (Ra) x Comprimento de corte (f variando)




Figura 5.6 - Rugosidade (Rmáx) x Comprimento de corte (f variando)




Figura 5.7 - Vibração na direção de avanço (RMS) x Comprimento de corte (f variando)




Figura 5.8 - Vibração na direção de corte (RMS) x Comprimento de corte (f variando)

As considerações sobre os gráficos das figuras 5.1 a 5.8 são válidas para os conjuntos dos ensaios restantes, cuja abrangência foi mostrada no capítulo anterior. Por questões de clareza e economia de espaço e no intuito de manter o texto conciso, deixamos de mostrar os gráficos restantes, correspondentes a todos os ensaios restantes.

É importante mencionar também que a quantidade de pontos mostrados em todos os gráficos anteriores foram estabelecidos de forma que não se comprometesse sua visualização e se propiciassem análises representativas em relação aos estágios de desgaste da ferramenta, que serão comentados a partir de agora.

As tendências observadas nesses gráficos serviram para a determinação do Status da ferramenta (aqui denominado de Status real), que será posteriormente comparado com o Status da ferramenta estimado pela rede neural (Status da rede).

Todas essas curvas representadas pelos gráficos das figuras 5.1 a 5.8 apresentaram um comportamento similar no que se refere à tendência de crescimento no tempo, pelos quais podemos distinguir 4 fases de desgaste da ferramenta, quais sejam: fase 1 (ferramenta nova), fase 2 (ferramenta em estágio intermediário de desgaste), fase 3 (ferramenta em estágio rápido de desgaste) e fase 4 (ferramenta gasta).

Para que esta divisão de "Status" da ferramenta pudesse ser feita, calculou-se o arco tangente do ângulo formado entre a reta que une os valores imediatamente consecutivos dos sinais RMS e o eixo do comprimento de corte, que representa a inclinação desta reta.

Cumpramos ressaltar que os valores numéricos dos arcos tangentes aqui adotados não se prestam a uma metodização, mas sim, apenas a uma convenção estabelecida neste trabalho, que serviu

para dividir os gráficos de forma didática nas regiões distintas segundo as 4 tendências diferentes observadas em relação ao estado da ferramenta.

De acordo com as inspeções visuais do desgaste realizadas concomitantemente aos ensaios e sua comparação posterior com o comportamento das curvas obtidas depreende-se que a divisão didática nessas 4 fases citadas é satisfatório, prestando aos objetivos propostos.

A seguir tem-se uma descrição das características de cada fase:

Fase 1 (ferramenta nova):

Nessa etapa, há uma ligeira queda nos valores de rugosidade e sinal de vibração em relação ao tempo. Predominou, portanto, uma tendência qualitativa de crescimento negativo de tais valores, verificando-se a conservação da derivada em valores negativos, até dado ponto da curva no qual se percebe outra tendência no desgaste da ferramenta. Além disso, essa fase é relativamente rápida quando comparada com as demais. Quantitativamente não houve valores bem definidos tais que se possa estabelecer uma regra geral, todavia, os mesmos não foram superiores a $\text{arc tg } 0,839$ (adotando-se o sentido anti-horário como referência). A essa fase estipulou-se ao Status o valor 1.

Fase 2 (ferramenta em estágio intermediário de desgaste):

Essa etapa é a mais longa entre todas. Nela há uma tendência dos valores de rugosidade e sinal de vibração se manterem aproximadamente constantes com o tempo, pois suas variações não foram drásticas, a menos de alguns pontos isolados.

Em relação aos sinais da derivada, porém, caracteriza-se por uma oscilação aleatória dos mesmos, com curvaturas positivas e negativas se alternando sem regras quantitativas perceptíveis.

Apesar disso, o valor absoluto das tangentes entre os diversos pontos consecutivos da curva oscilaram entre valores relativamente menores, com a maioria deles dentro da faixa até 30 graus de inclinação. A esse Status atribuiu-se o valor 2.

Fase 3 (ferramenta em estágio de desgaste rápido):

Aqui as oscilações são muito menos freqüentes e as curvas assumem tendência de derivada positiva com curvatura sucessivamente crescente, cuja inclinação foi aumentando até valores próximos a 45 graus, a partir de onde entra-se na última fase. A essa terceira fase atribuiu-se o Status 3 para a ferramenta, e é a fase crítica no processo de desgaste, pois ao fim desta, a ferramenta está totalmente deteriorada, podendo causar danos à peça ou à ferramenta, ou seja, é antes do limite do fim dessa fase 3 que o processo de usinagem deve ser interrompido e a ferramenta substituída.

Fase 4 (ferramenta gasta):

Esta fase é a mais rápida em comparação com as outras. Aqui a inclinação (sempre positiva) da curva experimenta grandes saltos. A derivada cresce abruptamente, levando logo o limite da curva no final dessa fase tender ao infinito, que é dizer que seu $\arctg$ aproxima de 1. Esta fase foi aqui chamada de Status 4, ferramenta gasta.

Como foi dito anteriormente, é antes dessa fase 4 que, no processo de usinagem convencional o operador deve providenciar a substituição da ferramenta, embora ele se utilize de critérios nem sempre confiáveis, pois esta decisão de substituição da ferramenta envolve considerações ligadas à natureza do ser

humano (por exemplo, o receio de comprometer a qualidade de uma peça pode levar o homem a uma troca muito prematura da ferramenta, aumentando os custos de usinagem).

A rede neural treinada, se funcionando em tempo real, forneceria de imediato a indicação do Status limite da ferramenta, constituindo-se em auxílio ao monitoramento do desgaste até o fim da vida da mesma. O valor limite do Status que a rede deverá fornecer será discutido no próximo item, 5.2.

Finalmente, a tabela 5.1 mostra, para algumas das condições de corte ensaiadas, os valores de comprimento de corte em metros a partir do qual se inicia o Status 4, de acordo com 4 diferentes parâmetros.

f (mm/volta)	v_c (m/min)	Ra	Rmax	RMS (avanço)	RMS (corte)
0,15	250	2764,60	2764,60	2714,34	2764,60
0,15	300	1696,34	1696,34	1633,63	1568,28
0,20	300	1528,78	1528,78	1528,78	1481,66

Tabela 5.1 - Valores de comprimento de corte (em metros) no início do Status 4 - para 4 diferentes critérios

Pode-se ver que, independentemente dos parâmetros escolhidos (rugosidades e sinais de vibração), os valores são bastante próximos entre si, mas conservam diferenças capazes de comprometer a confiabilidade. Por isso, esse método por si só não é suficiente para garantir uma estimativa perfeita, mas indica que o monitoramento via vibrações é um bom método para estabelecer o fim da vida da ferramenta nas condições de usinagem utilizadas nessa dissertação.

Além disso, o estabelecimento do fim da vida da ferramenta baseado na variação da inclinação da curva RMS de vibração x comprimento de corte, que pode ser facilmente implementado em tempo real, tem o inconveniente de que, durante alguns momentos do estágio intermediário da vida da ferramenta (Status 2), a inclinação da curva também cresceu rapidamente (é lógico que essa maior inclinação não se mantinha durante muito tempo neste estágio), o que poderia confundir tal procedimento.

Aí reside a propriedade da rede neural que, por indicar diretamente o Status da ferramenta, pode ser mais conveniente que outros métodos numéricos, algoritmos e métodos convencionais, no que concerne a questões de confiabilidade.

No item seguinte, discute-se os resultados obtidos pelo uso da rede "back-propagation", no estabelecimento do momento de fim de vida da ferramenta..

5.2 TREINAMENTO DA REDE NEURAL "BACK-PROPAGATION" A PARTIR DE PARÂMETROS DO ENSAIO DE USINAGEM

Dos 11 ensaios realizados com diferentes valores de avanço e velocidade de corte, 7 deles foram utilizados para treinamento da rede neural (os ensaios de números 1 a 7 da tabela 4.1, capítulo 4) e 4 para validação dos resultados sugeridos pela rede (os ensaios números 8 a 11 da tabela 4.1).

Numa primeira tentativa de utilização das redes neurais utilizou-se como parâmetros de entrada os seguintes: Velocidade de corte (v_c), avanço (f), comprimento de corte (l_c), sinais RMS na direção de corte e na direção de avanço, esperando-se obter como

saída as rugosidades R_a e $R_{máx}$ e a condição Status estimados pela rede neural.

Arquitetou-se a rede com as camadas de entrada e de saída, e mais uma única camada intermediária.

Realizou-se então primeiramente o treinamento de rede, onde informava-se a rede os cinco parâmetros de entrada e os três parâmetros de saída, de diversos momentos dos sete ensaios utilizados para treinamento. Nesta fase, a rede ficou rodando diversas horas (aproximadamente 205) até o fim do treinamento. Depois desta fase, começou a fase de validação dos resultados da rede. Aqui, somente eram fornecidos os dados de entradas da rede, retirados dos 4 ensaios separados para esta fase e a rede fornecia os valores de R_a , R_{max} e Status da ferramenta, para serem comparados com os valores reais obtidos dos ensaios.

A comparação entre as saídas da rede neural e os resultados reais obtidos nos ensaios de usinagem resultaram nas conclusões que se seguem:

- A rede neural só consegue ser sensível a partir de onde as rugosidades média e a máxima experimentam crescimento acentuado, não se verificando precisão numérica satisfatória desde o início do desgaste até o intervalo que corresponde ao fim do desgaste rápido (gráficos das figuras 5.9 e 5.10). Isto é, a rede neural foi capaz de uma resposta boa a partir do momento que corresponderia à fase final somente qualitativamente, em termos de tendências, mas não numericamente. O que se viu nesses citados gráficos se reflete nos outros ensaios usados para validação, onde somente a fase final do desgaste é bem definida.

- Por outro lado, a rede neural foi capaz de diferenciar os "Status" da ferramenta de maneira razoavelmente satisfatória praticamente durante todo o seu processo de desgaste até o fim da

vida, nos ensaios das figuras 5.11 e 5.12 (apesar da imprecisão numérica). Porém, nos ensaios mostrados nas figuras 5.13 e 5.14 a rede não conseguiu discernir claramente a diferença entre o Status 2 e o Status 3, o que é fundamental para o estabelecimento do fim de vida da ferramenta.

Tendo em vista a constatação de que apenas o Status da ferramenta foi razoavelmente bem discernido pela rede neural, e apenas em alguns casos, não se verificando boa sensibilidade em todo o processo de desgaste para as rugosidades, uma tentativa de melhora foi feita no sentido de verificar se a rede neural aumentaria a sensibilidade em relação ao Status da ferramenta. O aumento da precisão da rede é esperado teoricamente, devido à simplificação de dados, ou seja, concentração de esforços dos elementos processadores da rede em obter apenas uma única saída, não envolvendo outras saídas que não contribuam de forma decisiva para o estabelecimento do momento da troca da ferramenta.

Por esses motivos, isto é, permitir excluir os dados prolixos e restringir-se apenas à concisão de dados, é que, numa segunda etapa decidiu-se remodelar a rede neural de forma que forneça apenas a saída indicativa do Status da ferramenta para a determinação de seu momento crítico. Não se apresenta aqui o tratamento estatístico dos dados do primeiro modelamento pois acredita-se que a rede remodelada é melhor e mais conveniente.

Desse modo, manteve-se os mesmos parâmetros de entrada anteriores, mas agora estabelecendo-se como saída apenas um vetor relativo ao Status, ao invés da anterior, que compreendia além deste, a rugosidade e a rugosidade máxima.

Além disso, optou-se pela adoção de mais uma camada intermediária adicional (em relação à primeira rede), para aumentar o número de conexões entre os elementos processadores da rede.




Figura 5.9 - Rugosidade da rede x Rugosidade real




Figura 5.10 - Rugosidade máxima da rede x Rugosidade máxima real




Figura 5.11 - “Status da rede” x “Status real”




Figura 5.12 - “Status da rede” x “Status real”




Figura 5.13 - “Status da rede” x “Status real”




Figura 5.14 - “Status da rede” x “Status real”

Após cerca de 140 horas de treinamento e 600635 ciclos treinados (contra 205 horas aproximadamente e 1146742 ciclos de treinamento da primeira rede), obteve-se resultados na fase de validação que podem ser vistos nos gráficos das figuras 5.15 a 5.18, podendo-se concluir que:

- A rede neural tornou-se mais sensível no seu conjunto todo, mostrando que o parâmetro Status da ferramenta pode ser usado de modo suficientemente satisfatório para aplicações no monitoramento da usinagem (sua abordagem estatística será discutida mais adiante);

- Essa melhoria correspondeu às expectativas quando se decidiu pelo aprimoramento da rede neural, bem como o tempo e o ciclo de treinamento foram bem mais curtos, como seria de se esperar;

- A rede neural foi capaz de discernir bem um parâmetro ensinado, ao invés de vários deles simultaneamente;

Estabelece-se agora o Status limite da ferramenta através dos resultados da rede modificada, que é um intervalo dentro do qual se sugere a troca da ferramenta. Valores inferiores a esse Status limite podem subutilizar a vida da ferramenta, devido a trocas prematuras e valores superiores aumentam a probabilidade de se entrar na faixa onde a ferramenta se deteriora completamente, podendo causar danos irreversíveis ao material usinado.

Para tanto, lançou-se mão de recursos estatísticos, através da Curva de distribuição Normal ou Curva de Gauss, que é uma distribuição contínua de probabilidade.

Relembrando, a ferramenta deve ser substituída durante o Status 3, onde se garante que ela não foi subutilizada (Status 2), nem tem-se o risco de dano à peça e/ou à ferramenta (Status 4).




Figura 5.15 - “Status da rede” x “Status real”




Figura 5.16 - “Status da rede” x “Status real”




Figura 5.17 - "Status da rede" x "Status real"




Figura 5.18 - "Status da rede" x "Status real"

Por essa razão calculou-se a média X_m e o desvio padrão σ de todos os Status fornecidos pela rede dos ensaios da fase de validação que correspondam ao estágio 3 da ferramenta (Status real 3).

Assim, obteve-se: $X_{m3}(\text{rede}) = 2,966$ com $\sigma = 0,4261$.

Assumindo-se que a distribuição destes pontos em torno da média é normal, tem-se que 90% dos pontos estão entre os intervalos $(X_m - 1,67 \cdot \sigma)$ e $(X_m + 1,67 \cdot \sigma)$.

Esses limites são:

$$2,966 + 1,67 \sigma = 3,678 \quad e$$

$$2,966 - 1,67 \sigma = 2,254$$

Para saber-se o quanto esse intervalo poderia estar invadindo probabilisticamente o intervalo do Status 2, faz-se a mesma análise acima descrita com os valores de Status rede correspondentes ao Status real 2 e verificou-se onde ocorre sua intersecção com o Status 3.

Então:

$$X_{m2}(\text{rede}) = 2,1453 \quad e \quad \sigma = 0,2922$$

Então, os valores limites do intervalo de confiança foram:

$$2,1453 + 1,67 \sigma = 2,633$$

$$2,1453 - 1,67 \sigma = 1,6573$$

Assim, quando o valor de Status fornecido pela rede for maior que 2,633, tem-se 95% de chance de que realmente a ferramenta não está no estágio 2 (os outros 5% de diferença entre os 95% citados aqui e os 90% do intervalo citado estão para baixo de 1,6573).

E para verificar-se qual o valor limite superior que entra no intervalo de incerteza que incluiria a intersecção entre os valores

de Status 3 e 4, realizou-se o mesmo procedimento, para o intervalo correspondente ao Status 4. Aqui só nos interessa seu limite inferior, pois é aí que poderia haver uma intersecção com os valores limites do Status 3.

Dessa forma:

$$Xm_4 (\text{rede}) = 3,9228 \quad \text{e} \quad \sigma = 0,4697$$

Seu valor limite inferior é ; $3,9228 - 1,67 \sigma = 3,138$

Ou seja, se o valor fornecido pela rede for menor que 3,138, há 95% de probabilidade de que a ferramenta não esteja no estágio 4. A figura 5.19 mostra os limites de todos esses intervalos.

Portanto, conclui-se que os valores limites da saída (Status da rede) deverão estar compreendidos entre o limite mínimo de 2,633 e o máximo de 3,138, para que se decida a troca da ferramenta, pois valores nesse intervalo têm somente menos de 5% de chances de serem 2 (desperdiçando a ferramenta) , e menos de 5% de chances de serem Status 4 (danificando a peça e/ou a ferramenta). .

Em suma, pode-se afirmar com bastante certeza que a ferramenta está sendo trocada adequadamente, se tomar-se o intervalo em que:

$$2,633 < \text{Status rede} < 3,138$$

Conclui-se que:

Adotando o critério de Status dentro desse intervalo citado, há uma probabilidade alta de se estar utilizando a ferramenta convenientemente.




Figura 5.19 - Limites dos intervalos dos "Status"

CAPÍTULO 6

CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

A partir de tudo o que foi considerado nos capítulos anteriores, pode-se chegar a algumas conclusões:

- A rede neural da maneira como foi aqui projetada, permitiu a obtenção de um método capaz de estipular com boa probabilidade de acerto o "Status" de desgaste da ferramenta, o que permite otimização da utilização da ferramenta de corte;

- Os resultados confirmam as convicções de muitos autores sobre a adequação de utilização de redes neurais em sistemas de monitoramento do desgaste da ferramenta;

- O critério estabelecido por esse trabalho é particular e inerente às suas características peculiares, mas sua metodologia pode ser extrapolada para outras tentativas de utilização de redes neurais em torneamento e mesmo em outros processos de usinagem, que não sejam o torneamento;

- A rede neural pôde estipular bem o valor do "Status" nas condições que abrangeram as velocidades e avanços, desde as menores, até as maiores condições de corte ensaiados, sendo essas as condições típicas do torneamento em acabamento. Outrossim, é plausível que a rede neural daria boas respostas também para condições de corte que se afastassem desses intervalos testados;

- As tendências das rugosidades e sinais de vibração de sofrerem um abrupto crescimento na fase final de desgaste da ferramenta são muito mais conclusivas do que seus valores absolutos em si. Isto é, o monitoramento do desgaste da ferramenta

via vibrações é eficaz, justamente por detectar esse abrupto crescimento, ao passo que a indicação dos valores absolutos daqueles parâmetros, por si pode não indicar efetivamente o estado de desgaste da ferramenta;

- É certo que a rede neural não obteve a precisão máxima, visto que, como já foi visto anteriormente, seu processamento é baseado no funcionamento do cérebro humano, tendo as faculdades de “esquecer”, “lembrar”, “estimar”, “especular”, atividades essas tipicamente humanas - sujeitas a incertezas, portanto. Por outro lado, a rede neural, salvo por limitações tecnológicas, está isenta de outras facetas do comportamento humano, como fadigas, stresses, doenças, livrando-se assim de erros causados por cansaços, pressões externas, instabilidades emocionais, receios e males que acomodem os homens, por mais experientes e equilibrados que possam ser. Em suma, a rede neural é muito mais consistente que o ser humano, pois ela erra com muito menor frequência que o ser humano, desde que ela tenha aprendido a executar determinada tarefa.

Para trabalhos futuros, como continuação deste trabalho, ou aproveitando algumas das conclusões, sugere-se:

- Complementar o trabalho, uma vez mostrada sua eficácia do ponto de vista técnico, com considerações de análise econômica, tendo-se em vista as exigências dos sistemas de manufaturas correntes;

- Estender esse método para outros tipos de ferramentas e materiais de corte e diferentes processos de usinagem convencionais;

- A implementação da fase de validação da rede neural em tempo real para estabelecimento da vida da ferramenta em

operações industriais é uma tarefa factível e será objeto de trabalhos futuros.

BIBLIOGRAFIA

- 1) LUBBEN, RICHARD T., 1988, "Just-in-time, uma estratégia avançada de produção", pp. 3 a 29, Editora Mc Graw Hill.
- 2) DINIZ, A.E., 1989, "A rugosidade superficial da peça em processos de torneamento: critério de fim de vida da ferramenta e fatores de influência", tese de doutorado, UNICAMP, Campinas.
- 3) WASSERMAN, P. D. , 1989, "Neuralcomputing - Theory and Practice", Van Nostrand Reinhold, N.Y.
- 4) NOVASKI, O., 1993, "Custos de usinagem", Editora da UNICAMP.
- 5) TÖNSHOFF, H.K.; WULFSBERG, J.P.K; KÖNIG, W. & Van LUTTERVELT, C.A., 1988, "Developments and trends in monitoring and control of machining processes", Annals of the CIRP, vol.37(2), pp. 611 a 622.
- 6) EWINS, D. J., 1984, "Modal testing: theory and practice", Research studies presses ltd, London, cap. 4 e 5 e apêndice 3.
- 7) DINIZ, A. E., 1988, "Máquinas CN", Anais da SOBRACON - segundo simpósio sobre segurança do trabalho no setor da automação industrial, pp. 13.01 a 13.39.
- 8) DINIZ, A. E., 1994, "Monitoramento e controle automático do processo de usinagem", notas de aula, UNICAMP, S.P.
- 9) FERRARESI, D. , 1970, "Fundamentos da usinagem dos metais", editora Edgard Blücher, São Paulo, Brasil

10) SHAW, M.C.. 1986, "Metal cutting principles", Clarendon Press Oxford, N.Y., USA.

11) DE FILIPPI, A. & IPPOLITO, R. , 1969, "Adaptive control in turning: cutting forces and tool wear relationship for P10, P20, P30 carbides", Annals of the CIRP, vol 27, pp. 377-385.

12) LEE, L.C, LEE K.S & GAN, C.S., 1989, "On the correlation between dynamic cutting force and tool wear", Internacional Journal of Machine Tools and Manufacture, vol. 29(3), pp. 295-303.

13) STEIN, J.L. & CHURN, H.W. , 1990, "Analysis of power monitoring on AC induction drive systems , (em posse do autor).

14) DAN, L. & MATHEW, J. , 1990, "Tool wear and failure monitoring techniques for turning - a review", International Journal of machine tools and manufacture, vol. 30(4), pp. 579-598.

15) WARNECKE, G. & JENEWEIN, A., 1988, "A cutting force model for tool condition monitoring when turning with ceramic tools", Proceedings of the 16th north american manufacturing research conference, pp. 171-177.

16) KANNATEY-ASIBU JR., E. & DORNFELD, D.A., 1981, "Quantitative relationship for acoustic emission from orthogonal metal cutting", Journal of Engineering for Industry, vol. 103 (3), pp. 330-340.

17) BLUM, T. , 1988, "Study of acoustic emission monitoring in metal cutting", PhD Thesis, Keyo University, Tokyo, Japan.

18) BLUM, T. & INASAKI, I., 1990, "A study on acoustic emission from the orthogonal cutting process", Journal of Engineering for Industry, vol. 112. pp. 203-211.

19) BEATTIE, A. G., 1983, "Acoustic Emission principles and instrumentation", *Journal of Acoustic Emission*, vol.2, pp. 95-128.

20) 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*, vol. 17, pp. 154-160.

21) KAKINO, Y., 1984, "Monitoring of metal cutting and grinding processes by acoustic emission", *Journal of Acoustic Emission*, vol. 3(3), pp. 108-116.

22) JACOBSEN, S.L. & ARYE, R., 1956, "Engineering vibration applications to structures and machinery", McGraw-Hill, N.Y., USA.

23) LIANG, S.Y. & DORNFELD, D.A., 1987, "Deteccion of cutting tool wear using adaptive time series modeling of acoustic emission signals", "Sensors for Manufacturing" - M. K. Tse and D. A. Dornfeld Eds., ASME, pp. 27 - 38.

24) ARSHINOV, V. & ALEKSEEV, G., 1979, "Metal cutting theory and cutting tool design", Mir Publishers, Moscou, Russia.

25) COSIDINE, M.D. & ROSS, D.S., 1964, "Handbook of applied instrumentation", McGraw-Hill, N.Y., USA.

26) JIANG, Y. C. & XU, Z. H. , 1987, "In process monitoring of tool wear stage by the frequency band-energy method" *Annals of the CIRP*, vol. 36, pp 45 - 48.

27) RAO, B. S., 1986 , "Tool wear monitoring through the dynamics of stable turning", *Transactions of ASME, Journal of engineering for industry*, vol. 108, pp. 184-189.

28) AKIHIKO, N. & FUJITA, S. , 1989, "Development of a cutting tool failure detector" Bulletin of the Japan society of precision engineering, vol.23, pp. 134-139.

29) WELLER, J.E., SCHRIER, M.H. & WECHBRODT, B., 1969, "What sound can be expected from a worn tool?", Transactions of ASME, Journal of Engineering for Industry, vol.13, pp. 525-534.

30) MARTIN, P.; MUTEL, B. & DRAPIER, J.D., 1974, "Influence of lathe tool wear on the vibrations sustained in cutting", "Proceedings of the 15th. international machine tool design and research conference", pp. 251-274.

31) TAKEYAMA, H. , 1975, "Automation developments in Japan" , Annals of the third North american metalworking research conference, vol 3., pp. 675-685.

32) BONIFÁCIO, M. E. R., 1993, "Monitoramento do processo de torneamento de acabamento via sinais de vibração" , Dissertação de tese de mestrado, UNICAMP, S.P., pp. 1 - 87.

33) RIGO, A.L. ET ALI, 1993, "Workshop em aplicações de redes neurais", São Paulo, 1993. "Simpósio em Ferramentas Integradas de Desenvolvimento de Redes Neurais", MARINHO, A.S.

34) KRÖSE, BEN J.A. & VAN DER SMAGT, P., 1993, "An introduction to neural networks", University of Amsterdam.

35) CHOI, G. B.; WANG, Z. X. & DORNFELD, D. A. & TSUJINO, K. , 1990, "Development of an intelligent on-line tool wear monitoring system for turning operations" , Japan-USA Symposium of flexible automation, Kyoto, Japan.

36) RANGWALA, S. & DORNFELD, D. A. , 1990, "Sensor integration using neural networks for intelligent tool

condition monitoring", Journal of engineering for industry, vol 112, No. 3, pp. 219-218.

37) DORNFELD, D. A., 1990, "Neural network sensor fusion for tool condition monitoring", Annals of the CIRP, 39(1), pp.101-105.

38) McCULLOCH & PITTS, 1943, "A logical calculus of ideas imminent in nervous activity", Bulletin of mathematical biophysics, vol 5. , pp. 115-133.

39) ROSENBLATT, M. , 1958, "The Perceptron: a probabilistic model for information storage and organization in the brain", Psychological review, vol 65, pp. 386-408.

40) MINSKI & PAPERT, 1969, "Perceptrons", The MIT Press, Cambridge, MA.

41) KOHONEN, T., "Associative Memory: a system-theoretical approach", Springer-Verlag, 1984.

42) HOPFIELD, 1982, "Neural networks and physical systems with emergent collective computational abilities", Proc. nat. Acad. Sci, USA, vol 79, pp. 2554-2558.

43) FUKUSHIMA, K. , 1988, "Neocognitron: a hierarchical neural network capable of visual pattern recognition", Neural Networks vol 1. pp. 119-130.

44) ROSA, J. L., 1993, "Redes neurais e lógicas formais em processamento de linguagem natural", tese de mestrado, UNICAMP, S.P., pp. 22 - 41, 44 - 54 e 126 - 140.

45) RUMELHART, D. E. & McLELLAND, J.L., 1986, "Parallel distributed processing-explorations in the microstructure of cognition", vol 1 - Foundations, The MIT Press.

46) TESHIMA ,T., SHIBASAKA,T., TAKUMA, M. & YAMAMOTO A., 1993, "Estimation of cutting life by processing

tool image data with neural network", Annals of the CIRP, vol. 42(1), pp. 59 a 62.

47) JAMMU, V.B., DANAI, K. & MALHIN, S., "Unsupervised Neural network for tool breakage detection in turning", 1993, Annals of the CIRP, vol. 42 (1), pp. 67 a 70.

48) SAKAKURA, M. & INASAKI I., 1992, "A neural network approach to the decision-making process for grinding operation", Annals of the CIRP, vol 41(1), pp. 353 a 356.

49) NASCIMENTO, C. & YAMAMOTO, C., 1993, "Modelagem de processos químicos via redes neurais", Workshop em aplicações de redes neurais, São Paulo, S.P.

50) CHIU, S. L., MORLEY, D. J. & MARTIN, J.F., 1986, "Sensor Data Fusion in a parallel processor", Proc. IEEE, Int. Art. on Robotics and Automation, Kyoto, Japan.

51) CATÁLOGO C-1000:3-SPA SANDVIK-COROMANT, 1991, "HERRAMIENTAS Y PLAQUITAS PARA TORNEAR"

52) "ANSim USER'S MANUAL - VERSION 2.02", 1989, Manual de instalação e utilização produzido pela S.A.I.C.TM, USA.