



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”

Faculdade de Engenharia de Ilha Solteira
Departamento de Engenharia Mecânica
Programa de Pós-Graduação em Engenharia Mecânica

REDES NEURAIS – APLICAÇÃO NO MONITORAMENTO DA VIDA DE FERRAMENTAS DE CORTE

Rogério Pinto Alexandre

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira – UNESP, como parte dos requisitos para obtenção do título de **Mestre em Engenharia Mecânica**.

Orientador: Prof. Dr. João Antonio Pereira
Co-orientador: Prof. Dr. Hidekasu Matsumoto

Ilha Solteira – SP, janeiro de 2005.

Livros Grátis

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

Milhares de livros grátis para download.

***REDES NEURAIIS – APLICAÇÃO NO MONITORAMENTO DA VIDA DE FERRAMENTAS DE
CORTE***

ROGÉRIO PINTO ALEXANDRE

Esta dissertação foi julgada adequada para obtenção do título de **MESTRE EM ENGENHARIA MECÂNICA** na área de concentração **MECÂNICA DOS SÓLIDOS** e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Mecânica.

Prof. Dr. Gilberto Pechoto de Melo / Coordenador do Curso

BANCA EXAMINADORA

Prof. Dr. João Antonio Pereira / Orientador

Prof. Dr. Amauri Hassui

Prof. Dr. Gilberto Pechoto de Melo

Ilha Solteira, Janeiro de 2005

*Dedico este trabalho aos meus pais
Marcílio e Paulina e a minha noiva
Egiane.*

AGRADECIMENTOS

A Deus, fonte de toda vida.

Aos meus pais, que em todos os momentos estiveram presentes com incentivo, apoio e carinho, e aos meus irmãos Eduardo e Evandro que fazem parte da minha vida.

A minha noiva Egiane, que sempre esteve ao meu lado com seu amor, carinho e alegria, me apoiando e contribuindo muito para a realização deste trabalho.

Ao Prof. Dr. João Antonio Pereira pela orientação, amizade e incentivo desprendido e por todo aprendizado que a convivência nos proporcionou.

Ao Prof. Dr. Hidekasu Matsumoto por toda colaboração, orientação, amizade e dedicação, principalmente na montagem experimental.

Aos meus amigos de mestrado Dráusio Vicente de Almeida, Edlene Cenedese e Odacir de Almeida Neves pela amizade e incentivo.

Aos alunos de iniciação científica Ismael e João, pela ajuda dispensada na realização dos ensaios experimentais.

Aos técnicos Carlos Santana e Marino Teixeira Caetano pela colaboração na montagem experimental.

Ao Prof. Dr. Adyles Arato Júnior pelas sugestões a auxílio na montagem experimental.

Ao Prof. Dr. Carlos Minussi e a doutoranda Mara Lucia, do departamento de Engenharia Elétrica – FEIS, pela ajuda dispensada relativa a Redes Neurais.

A todos os professores e amigos do Departamento de Engenharia Mecânica de Ilha Solteira.

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

RESUMO

ABSTRACT

1. INTRODUÇÃO	1
2. REVISÃO BIBLIOGRÁFICA	4
3. MONITORAMENTO DO PROCESSO DE USINAGEM	11
3.1. INTRODUÇÃO	11
3.2. FERRAMENTAS DE CORTE.....	12
3.2.1. DESGASTE	12
3.2.2. VIDA DA FERRAMENTA	17
3.3. MÉTODOS DE MONITORAMENTO	19
3.4. COMPONENTES DE UM SISTEMA DE MONITORAMENTO	20
3.4.1. SENSORES	21
3.4.2. CONDICIONAMENTO DO SINAL.....	21
3.4.3. MODELOS PARA EXTRAÇÃO DE INFORMAÇÕES RELEVANTES (<i>SIGNAL FEATURES</i>).....	22
3.4.4. ESTRATÉGIA	22
3.5. INSTRUMENTAÇÃO APLICADA AO MONITORAMENTO DA VIBRAÇÃO.....	22
4. REDES NEURAIS ARTIFICIAIS	25
4.1. INTRODUÇÃO	25
4.2. NEURÔNIO BIOLÓGICO	26
4.3. NEURÔNIO ARTIFICIAL	27
4.4. FUNÇÕES DE ATIVAÇÃO	28
4.5. RNAs DE SIMPLES CAMADAS	29
4.6. RNAs MULTICAMADAS	30
4.7. TREINAMENTO.....	32

4.8.	REGRAS DE TREINAMENTO	33
4.9.	ALGORITMO BACKPROPAGATION.....	35
4.10.	TÉCNICAS DE REDUÇÃO DE DADOS	37
5.	MATERIAIS, EQUIPAMENTOS E PROCEDIMENTOS EXPERIMENTAIS	41
5.1.	INTRODUÇÃO	41
5.2.	EQUIPAMENTOS UTILIZADOS E MONTAGEM DO SISTEMA DE MEDIÇÃO	41
5.3.	PROGRAMA DE AQUISIÇÃO E AMOSTRAGEM	44
5.4.	ENSAIOS PRELIMINARES	46
5.5.	ENSAIOS DE DESGASTE	48
6.	IDENTIFICAÇÃO DO DESGASTE DA FERRAMENTA UTILIZANDO SINAIS DE VIBRAÇÃO.....	54
6.1.	INTRODUÇÃO	54
6.2.	INFLUÊNCIA DA RIGIDEZ DOS DISPOSITIVOS DE FIXAÇÃO E DA PEÇA NO ACABAMENTO SUPERFICIAL	54
6.2.1.	ENSAIOS UTILIZANDO FERRAMENTA COM COBERTURA	55
6.2.2.	ENSAIOS UTILIZANDO FERRAMENTA SEM COBERTURA	59
6.3.	CORRELAÇÃO ENTRE A RUGOSIDADE DA PEÇA E OS SINAIS DE VIBRAÇÃO	62
6.4.	TREINAMENTO DA REDE NEURAL ARTIFICIAL.....	65
6.4.1.	VALORES RMS DOS SINAIS DE VIBRAÇÃO – FERRAMENTA COM COBERTURA	67
6.4.2.	DECOMPOSIÇÃO WAVELET DOS SINAIS DE VIBRAÇÃO – FERRAMENTA COM COBERTURA	71
6.4.3.	VALORES RMS DOS SINAIS DE VIBRAÇÃO – FERRAMENTA SEM COBERTURA	77
6.4.4.	DECOMPOSIÇÃO WAVELET DOS SINAIS DE VIBRAÇÃO – FERRAMENTA SEM COBERTURA	83
7.	CONCLUSÕES	91
7.1.	SUGESTÕES PARA TRABALHOS FUTUROS	92
	REFERÊNCIAS.....	93
	ANEXO 1	98

LISTA DE FIGURAS

Figura 3.1 – Regiões de desgaste da ferramenta (LIM et al., 2001).....	13
Figura 3.2 – Falhas em ferramentas de corte (WEINGAERTNER, 2002): (a) desgaste de flanco; (b) desgaste de cratera; (c) trincas térmicas; (d) lascamentos; (e) fratura.	15
Figura 3.3 – Aresta postiça de corte (DINIZ et al., 2000).....	16
Figura 3.4 – Esquema de montagem do sistema de monitoramento (HARA, 1995).	23
Figura 4.1 – Neurônio biológico (WASSERMAN, 1989)	27
Figura 4.2 – Neurônio artificial (WASSERMAN, 1989).....	27
Figura 4.3 – Neurônio artificial com função de ativação (WASSERMAN, 1989).....	28
Figura 4.4 – Funções de ativação (WASSERMAN, 1989)	29
Figura 4.5 – Rede neural simples camadas (WASSERMAN, 1989)	30
Figura 4.6 – Rede neural duas camadas (WASSERMAN, 1989)	31
Figura 4.7 – Neurônio artificial com função de ativação $1/(1 + e^{-NET})$ (WASSERMAN, 1989) ..	35
Figura 4.8 – Etapas principais do processo de classificação (SANTOS, 2000).....	38
Figura 4.9 - Exemplos de Wavelets (SANTOS, 2000).....	39
Figura 4.10 – Relação entre frequência e escala (SANTOS, 2000)	40
Figura 5.1 – Esquema de montagem do sistema de monitoramento.	42
Figura 5.2 – Acelerômetro acoplado no porta-ferramenta.	43
Figura 5.3 – Posicionamento do acelerômetro e do porta-ferramentas no torno.....	43
Figura 5.4 – Desenho dos corpos de prova utilizados.	44
Figura 5.5 – Posições para amostragem dos sinais nos corpos de prova	45
Figura 5.6 – Configuração do software <i>DasyLab</i> para aquisição de dados.....	45
Figura 5.7 – Espectro do sinal medido nas proximidades dos mancais do torno.....	47
Figura 5.8 – Espectro do sinal medido no porta-ferramentas.....	48
Figura 5.9 – Medição da rugosidade utilizando um rugosímetro digital.....	50
Figura 6.1 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 630 rpm.....	55
Figura 6.2 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 800 rpm.....	56
Figura 6.3 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 1000 rpm.....	57

Figura 6.4 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 1250 rpm.....	58
Figura 6.5 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta sem cobertura – rotação 1000 rpm.....	60
Figura 6.6 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta sem cobertura – rotação 1250 rpm.....	60
Figura 6.7 – Medidas de rugosidade utilizando ferramenta sem cobertura – rotações 1000 e 1250 rpm.....	61
Figura 6.8 – Variação da rugosidade – rotação 1250 rpm.....	63
Figura 6.9 – Variação dos valores RMS dos sinais de vibração – rotação 1250 rpm.	64
Figura 6.10 – Status da rede utilizando o primeiro conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm.....	69
Figura 6.11 – Status da rede utilizando o segundo conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm.....	69
Figura 6.12 – Status da rede utilizando o terceiro conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm.....	70
Figura 6.13 – Status da rede utilizando o quarto conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm.....	70
Figura 6.14 –Representação esquemática da decomposição wavelet do sinal de vibração	72
Figura 6.15 – Status da rede utilizando o primeiro conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm	73
Figura 6.16 – Status da rede utilizando o segundo conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm	74
Figura 6.17 – Status da rede utilizando o terceiro conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm	74
Figura 6.18 – Status da rede utilizando o quarto conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm	74
Figura 6.19 – Gráfico comparativo com os resultados obtidos utilizando valores RMS e coeficientes wavelet, para a ferramenta com cobertura e rotação 1250 rpm.....	76
Figura 6.20 – Status da rede utilizando o primeiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm	78
Figura 6.21 – Status da rede utilizando o segundo conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm	78

Figura 6.22 – Status da rede utilizando o terceiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm	79
Figura 6.23 – Status da rede utilizando o quarto conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm	79
Figura 6.24 – Status da rede utilizando o primeiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm	80
Figura 6.25 – Status da rede utilizando o segundo conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm	81
Figura 6.26 – Status da rede utilizando o terceiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm	81
Figura 6.27 – Status da rede utilizando o quarto conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm	81
Figura 6.28 – Status da rede utilizando o primeiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm.....	84
Figura 6.29 – Status da rede utilizando o segundo conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm.....	84
Figura 6.30 – Status da rede utilizando o terceiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm.....	84
Figura 6.31 – Status da rede utilizando o quarto conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm.....	85
Figura 6.32 – Status da rede utilizando o primeiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm.....	86
Figura 6.33 – Status da rede utilizando o segundo conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm.....	86
Figura 6.34 – Status da rede utilizando o terceiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm.....	87
Figura 6.35 – Status da rede utilizando o quarto conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm.....	87
Figura 6.36 – Gráfico comparativo com os resultados obtidos utilizando valores RMS e coeficientes wavelet, para a ferramenta sem cobertura e rotação 1000 rpm.	89
Figura 6.37 – Gráfico comparativo com os resultados obtidos utilizando valores RMS e coeficientes wavelet, para a ferramenta sem cobertura e rotação 1250 rpm.	89

LISTA DE TABELAS

Tabela 3.1 – Métodos de monitoramento (DAN et al., 1990).....	20
Tabela 5.1 – Parâmetros para o torneamento.	46
Tabela 6.1 – Configuração e parâmetros de treinamento da RNA.....	67
Tabela 6.2 – Saída da RNA para os diferentes estágios de desgaste da ferramenta.....	68
Tabela 6.3 – Comparação entre o percentual de acertos da RNA, treinada utilizando valores RMS dos sinais de vibração e rotação 1250 rpm, para a ferramenta com cobertura.....	71
Tabela 6.4 – Configuração e parâmetros de treinamento da RNA utilizando coeficientes wavelet	73
Tabela 6.5 – Comparação entre o percentual de acertos da RNA, treinada utilizando valores RMS dos coeficientes wavelet e rotação 1250, para a ferramenta com cobertura.	75
Tabela 6.6 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos sinais de vibração para a ferramenta sem cobertura e rotação de 1250 rpm.....	80
Tabela 6.7 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos sinais de vibração para a ferramenta sem cobertura e rotação de 1000 rpm.....	82
Tabela 6.8 – Configuração e parâmetros de treinamento da RNA utilizando coeficientes wavelet	83
Tabela 6.9 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos coeficientes wavelet para a ferramenta sem cobertura e rotação de 1250 rpm.....	85
Tabela 6.10 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos coeficientes wavelet para a ferramenta sem cobertura e rotação de 1000 rpm.	88

Resumo

Este trabalho discute a utilização de Redes Neurais Artificiais na avaliação da evolução do desgaste da ferramenta de corte no processo de torneamento a partir dos níveis de vibração do sistema porta-ferramenta – ferramenta – peça. Os níveis de desgaste foram definidos em termos da rugosidade superficial da peça e desgaste de flanco da ferramenta e posteriormente, os valores de vibração medidos no porta ferramenta, foram correlacionados com esses níveis de desgaste. Foram realizados diversos ensaios utilizando o aço ABNT 1045, com ferramentas de metal duro sem cobertura e com cobertura de nitreto de titânio. Os testes foram efetuados utilizando as rotações 630, 800, 1000 e 1250 rpm, variando-se a velocidade de corte entre 100 e 200 m/min. Os sinais de vibração foram processados e analisados utilizando valores RMS (*Root Mean Square*) e a Transformada Wavelet, sendo que neste caso, foram extraídos os valores RMS dos coeficientes wavelet. Os dados obtidos foram utilizados nas fases de treinamento e validação das redes neurais empregadas, utilizando o algoritmo *Backpropagation*. Os dados foram agrupados em quatro estágios que classificam o nível de desgaste da ferramenta em estágio inicial, estágio intermediário, estágio avançado e estágio crítico de desgaste. Os testes mostraram que a utilização dos valores RMS do sinal de vibração pode levar a resultados satisfatórios, entretanto, houve algumas situações de insucesso. Alternativamente, a rede neural quando treinada com os valores RMS dos coeficientes wavelet apresentou uma melhor capacidade de identificação, com um percentual de acerto maior do que quando treinada apenas com os valores RMS dos sinais de vibração. Os resultados mostram que o monitoramento da vibração da ferramenta e a utilização de redes neurais artificiais para identificação dos diferentes estágios da ferramenta, podem ser utilizados para se estabelecer o fim de vida da mesma no processo de torneamento. A utilização da Transformada Wavelet na extração dos parâmetros usados no treinamento da rede mostrou ser mais eficiente para a identificação da evolução do desgaste de ferramentas.

Palavras chaves: Redes Neurais, Torneamento, Desgaste, Monitoramento, Wavelet.

Abstract

This work discusses the use of Artificial Neural Networks (ANN) for the evaluation of tool wear in turning operations by using the vibration of the tool holder – tool – workpiece system. The wear levels were defined in terms of the surface roughness and flank wear of the cutting tool and later on, the vibration measured in the tool holder were correlated with those wear levels. Several experiments were carried out at different cutting conditions using ABNT 1045 steel as the workpiece material, the surface roughness were measured for carbide cutting tools without coating and with coating of titanium nitride. The tests were made using the rotations 630, 800, 1000 and 1250 rpm, being varied the cutting speed between 100 and 200 m/min. The vibration signals were processed and analyzed using RMS (Root Mean Square) values and the Wavelet Transform, in the later case; the RMS values were extracted from the wavelet coefficients. The obtained data were used in the training phases and validation of the neural network, using the Backpropagation algorithm. The data were settled in four groups that classify the level of the tool wear, initial, intermediary, advanced and critical. The experiments showed that the use of RMS values of the vibration signals can bring to satisfactory results, however, the neural network trained with the RMS values from the wavelet coefficients presented a better identification capacity, with a larger percentile of success, than that when just RMS values of the vibration signals were taken. The results show that the monitoring of the vibration of the tool holder–tool–workpiece system and the use of artificial neural network for identification of the different state of the tool, they can be used to settle the end of the tool life in the turning process. It was also evidenced the potentiality of Transformed Wavelet to be used together with neural network in the monitoring of the evolution of the wear of cutting tools in the turning process.

Keywords: Neural Network, Turning, Wear, Monitoring, Wavelet.

CAPÍTULO 1

1. INTRODUÇÃO

A adoção do monitoramento da automação em usinagem, tem sido encorajada pela necessidade de se manter uma alta qualidade dos produtos fabricados em larga escala. A produção em larga escala por vezes resulta em um aumento de tempos improdutivo, gerados pela interrupção do processo devido às falhas freqüentes nas máquinas-ferramenta. Com isso, nos últimos anos, os sistemas de monitoramento e controle em tempo real do processo de usinagem, com o objetivo de desenvolver detectores de falhas no processo de usinagem (principalmente o fim de vida da ferramenta), obtenção da usinagem não assistida (sem a participação do homem) e otimização dos recursos de usinagem, passaram a ser considerados como componentes fundamentais da automação (WEINGAERTNER et al., 2002).

No monitoramento convencional (manual) o operador de máquina-ferramenta pode detectar se uma ferramenta está em condições de uso observando a operação de usinagem e associando seus sentidos a padrões definidos à partir da experiência. Estes padrões de desgaste, são informações sensoriais armazenadas em seu cérebro através da experiência, adquirida ao longo dos anos de trabalho com o processo de corte do metal. As informações sensoriais obtidas para a tomada de decisão são normalmente dos seguintes tipos:

- a) Visual - a cor do cavaco, a presença de fumaça e a superfície acabada da peça usinada;
- b) Auditiva - o som gerado pela ação de abrasão do flanco da ferramenta contra a peça;
- c) Olfato - o cheiro de fumaça gerado pelo desgaste durante a usinagem.

Em muitos casos, a informação de um dos sentidos, por exemplo, a auditiva, pode não ser suficiente e a informação visual pode também ser necessária, ou mesmo a associação delas. Neste caso, a tomada de decisão é subjetiva e depende exclusivamente do operador. O fato é que operadores de máquinas-ferramenta em vários casos não são bem sucedidos em suas rotinas de monitoramento, trocando as ferramentas, na maioria das vezes, muito antes

desta atingir um nível de desgaste que possa causar danos à peça usinada (SANTOS et al., 1999).

A determinação do momento ideal para a substituição da ferramenta ainda é o ponto chave neste contexto, pois são vários os fatores que influem no desgaste da ferramenta e a separação, bem como, a extração das informações mais relevantes, para avaliação da vida da ferramenta, não é imediata.

As falhas na ferramenta de corte, provocadas por desgastes (contínuas) ou avarias (aleatórias), afetam a qualidade do produto direta e significativamente. Assim, a detecção em tempo real de indícios da fratura, que sempre ocorre inesperadamente e pode provocar danos irreversíveis na peça ou até na máquina-ferramenta, é crucial para a automação de processos (WEINGAERTNER et al., 2002).

As Redes Neurais Artificiais (RNAs) são técnicas computacionais baseadas em modelos matemáticos inspirados nos neurônios biológicos dos organismos inteligentes, que têm se mostrado bastante atraentes (promissoras) para o monitoramento, controle e automação de processos (BERNIERI et al., 1994). Essas técnicas são excelentes ferramentas para o reconhecimento de padrões (SANTOS, 2000), mostram um número surpreendente de características do cérebro, por exemplo, o aprendizado por experiência, generalização a partir de exemplos anteriores e abstração das características essenciais de entradas que também contêm um percentual de dados irrelevantes (WASSERMAN, 1989).

A habilidade das RNAs em solucionar problemas complexos e variados tem as tornado uma abordagem interessante, que pode ser aplicada em diversas áreas de engenharia e ciências aplicadas (SILVA et al., 2001; BARRETO, 2002), tais como: classificador de texturas (MARTINS et al., 2002), polímeros (FERNANDES et al., 2001; LOTTI et al., 2001), redes de comunicação e engenharia elétrica (SILVA et al., 2001), entre outros. Essa característica tem despertado um grande interesse na adoção de RNAs na área de monitoramento e detecção de falhas, e a sua utilização nesta área tem-se mostrado bastante promissora (ORTH, 2001; ÖZEL et al., 2002; LEE et al., 1996; HABER et al., 2003).

Este trabalho propõe a utilização de Redes Neurais Artificiais em sistemas de monitoramento, utilizando sinais de vibração para determinação e classificação do estado da vida de uma ferramenta de corte, no qual os sinais são obtidos (coletados) através de sensor, posicionado em local estratégico da máquina. Os sinais serão processados e analisados utilizando métodos e algoritmos de pré-processamento adequados, visando gerar um conjunto de dados reduzido que contenha as principais informações do sinal. Esses dados serão

posteriormente utilizados no treinamento da RNA, que poderá ser utilizada para o monitoramento e a identificação do estado da ferramenta de corte.

Inicialmente, será apresentada uma revisão bibliográfica, no capítulo 2, abordando assuntos relativos ao processo de usinagem e ferramentas de corte, monitoramento do processo de usinagem, técnicas de redução de dados e a utilização de redes neurais artificiais aplicadas no monitoramento de ferramentas de corte.

No capítulo 3 são apresentadas informações acerca de ferramentas de corte, tipos de desgastes, avarias e vida da ferramenta, mostrando os principais componentes de um sistema de monitoramento utilizados para monitorar o desgaste de ferramentas de corte, tais como, sensores, condicionamento do sinal, estratégias, entre outros.

No capítulo 4 são apresentados os fundamentos básicos acerca de Redes Neurais Artificiais, neurônios biológico e artificial, redes simples e multicamadas, tipos de treinamento e regras de treinamento. São discutidos também os aspectos das Técnicas de Redução de Dados utilizadas para realçar e separar as informações relevantes do sinal, visando reduzir a grande quantidade de informações geradas na fase de aquisição de dados.

O capítulo 5 descreve os materiais, equipamentos e procedimentos experimentais adotados na realização dos ensaios. No capítulo 6, são apresentados os resultados e as discussões da utilização de RNAs no monitoramento da vida da ferramenta de corte no processo de usinagem e finalmente, o capítulo 7 apresenta as conclusões e sugestões para trabalhos futuros.

CAPÍTULO 2

2. REVISÃO BIBLIOGRÁFICA

A implementação e utilização eficiente de um sistema de monitoramento não é uma tarefa simples de ser executada, pois há uma ampla variedade de processos de usinagem, que podem ser usados em vários campos de atuação, sendo requerido um levantamento de muitas informações específicas do processo que se deseja monitorar.

Destaca-se neste capítulo alguns aspectos importantes no monitoramento do processo de usinagem, abordando assuntos relativos à utilização de características de múltiplos sinais, para a predição da vida da ferramenta de corte, a adoção de diferentes tipos de sensores, a extração de informações dos dados e influência da qualidade destas informações no processo de identificação do desgaste da ferramenta, a integração de um sistema de monitoramento com um sistema de tomada de decisões e a utilização de redes neurais artificiais como ferramenta.

Um dos fatores predominantes para se obter bons resultados num sistema de monitoramento, isto é, a correta predição do momento adequado para a substituição da ferramenta de corte, está fortemente relacionado ao tipo de sinal que será monitorado, por exemplo, força de corte, vibração e/ou emissão acústica, bem como o número de sensores que serão utilizados para adquirir os sinais.

Zou, Hong e Rahman (1995) verificaram que há muitos critérios de fim de vida da ferramenta que dependem da maneira do desgaste, considerações econômicas, tolerância dimensional da peça e desgaste da superfície. No entanto, o sinal medido por um sensor, força de corte, por exemplo, usualmente representa a condição do desgaste da ferramenta contribuído por uma zona de desgaste diferente. Isso significa que é difícil definir um critério de desgaste, com base nos sinais que contêm informações que representam uma combinação de diferentes formas e zonas de desgaste da ferramenta. Quando múltiplas características dos sinais são usadas, a resposta não pode ser vista claramente, e a predição da vida da ferramenta pode ser não confiável. Neste trabalho, foi realizada uma investigação sobre o critério de fim de vida da ferramenta em operações de desbaste, utilizando um torno CNC para realização dos experimentos. Utilizou-se uma rede neural artificial, com o algoritmo de retropropagação

(Backpropagation), para distinguir os padrões do desgaste da ferramenta, representado por múltiplas características extraídas da força de avanço, pela técnica da Transformada Wavelet. Os resultados experimentais mostraram que os sinais contendo múltiplas características, extraídas do sensor, quando aplicados com RNAs no processo de identificação, distinção e tomada de decisão, servem para monitorar o desgaste da ferramenta, de acordo com o critério adotado (alteração significativa na mudança de estágio de desgaste normal para acelerado), sobre uma ampla faixa de condições de corte.

No trabalho de Silva et al. (1998), características baseadas no espectro de frequência e transformações estatísticas de um número de sensores de sinais, foram estudados com o objetivo de obter uma indicação confiável da evolução do desgaste da ferramenta. O experimento foi realizado num centro de usinagem CNC, no qual cinco sensores monitoraram dados sobre vibração, emissão acústica, corrente do motor e forças de corte, utilizando métodos de análises estatísticos e análise de frequência. Foram utilizados dois tipos de RNAs: Self Organising Map (SOM) e Adaptive Resonance Theory (ART). As duas redes neurais foram treinadas com 15 características extraídas dos cinco sensores. Verificou-se para ambas as redes, maior precisão na indicação do estado da ferramenta usando o conjunto completo dos dados contendo todas as características extraídas; eliminando três das mais fortes características, a classificação do estado da ferramenta ainda foi obtida, mas com precisão reduzida para ambas as redes, sendo, neste caso, representada a ocorrência de falha extrema nos sensores utilizados.

A literatura mostra também o monitoramento de outras variáveis (parâmetros) para avaliação do desgaste. Tomkiewicz (2001) utiliza técnicas de processamento e redes neurais artificiais para estimar ou classificar os parâmetros do desgaste. O trabalho aborda a utilização de sinais de uma câmera digital no porta ferramentas para a estimação contínua e a classificação de ferramentas num torno controlado numericamente, através de RNA. Conclui-se que o treinamento da RNA usada para estimar o desgaste da ferramenta, utilizando o algoritmo de treinamento Levenberg-Marquardt, requer dados bem preparados e que o desgaste da ferramenta pode ser estimado pela superfície desgastada da peça.

Outro aspecto importante, além da análise da quantidade de dados monitorados, é a qualidade das informações obtidas. Weingaertner (2002) verificou que o sucesso dos sistemas de monitoramento tem uma forte influência na qualidade das informações extraídas dos sinais coletados e do algoritmo de inteligência computacional usado para analisá-las. No primeiro caso, a técnica de multisensores é atrativa, principalmente porque a perda de sensibilidade de

um sensor pode ser compensada pela informação captada por outro. No segundo, a abordagem de modelagem inteligente, usando redes neurais artificiais e/ou lógica nebulosa, destaca-se pela habilidade em descrever características não-lineares, típicas dos processos de usinagem.

Há vários esquemas para a aquisição de dados, envolvendo posicionamento do sensor (próximo ao local onde se deseja adquirir os sinais) e tipo de sensor utilizado (emissão acústica, força de corte, vibração e corrente do motor, por exemplo), além de métodos que serão utilizados no processamento dos sinais adquiridos.

Kamarthi and Pittner (1997) apresentam a potencialidade de esquemas de representação de dados de sensores para sinais de força e vibração no contexto de estimação do desgaste da ferramenta em processos de torneamento. Dados de experimentos de torneamento foram usados para comparar a performance dos métodos baseados em Transformada Rápida de Fourier (FFT) e Transformada Wavelet (TW). O método baseado no modelo TW pode ser recomendado para sinais de força, enquanto métodos baseados em FFT aparecem ser uma melhor combinação para sinais de vibração.

Xiaoli Li (2002) mostra uma breve revisão das pesquisas realizadas utilizando Emissão Acústica (EA) para monitoramento do desgaste da ferramenta durante o torneamento, abordando os seguintes assuntos: a) geração de EA no processo de usinagem dos metais e classificação de sinais de EA; b) processamento de sinais de EA com várias metodologias, incluindo FFT, Transformada Wavelet, etc.; c) estimação da condição do desgaste da ferramenta, incluindo classificação de características, lógica fuzzy, rede neural e sensor e fusão de dados. Mostrou-se que através da transformada wavelet é possível decompor o sinal de EA em diferentes bandas de frequência, e que os valores RMS extraídos da decomposição de cada sinal para cada banda de frequência, foram usados como característica de monitoramento para o desgaste da ferramenta.

Hara (1995) discute 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 que, juntamente com um sistema de aquisição, adquirem os sinais de vibração. Realizou-se ensaios de torneamento em aço ABNT 4340 variando-se as condições de usinagem (velocidade de corte e avanço). Posteriormente, executou-se uma rede neural retropropagação, tendo como valores de entrada os valores RMS dos sinais de vibração e as condições de usinagem, e como valor de saída a indicação do estado de desgaste da ferramenta.

Os sistemas de monitoramento fornecem respostas em tempo real, a partir da análise de informações extraídas, através da utilização de técnicas de redução de dados, como Transformada Wavelet e Transformada de Fourier, em conjunto com ferramentas de tomadas de decisão, como lógica fuzzy e redes neurais artificiais, resultando em respostas rápidas e com maior precisão. A supervisão em tempo real do desgaste da ferramenta é a tarefa mais difícil no contexto de monitoramento de ferramenta de corte, segundo Tomkiewicz (2001).

Uma Rede Neural Artificial baseada no monitoramento do desgaste da ferramenta é apresentada por Liu et al. (1999) para operações de torneamento. O algoritmo é baseado nas condições de corte (avanço e velocidade de corte) e nas forças de cortes medidas, que são usadas como entrada da RNA. Neste experimento as forças de corte foram amostradas a 2000 Hz, utilizando um filtro passa baixa com frequência de corte a 100 Hz. O processo é interrompido periodicamente para verificar o desgaste da ferramenta. Inicialmente, a RNA é treinada com um conjunto de testes, que abrangem diversas faixas de velocidade de corte e avanço, e a medida correspondente do desgaste da ferramenta. Posteriormente, o algoritmo de treinamento é implementado para o monitoramento em tempo real do desgaste da ferramenta em operações de torneamento.

A utilização de Redes Neurais Artificiais para monitorar o desgaste da ferramenta, utilizando o algoritmo de retropropagação foi abordada no trabalho desenvolvido por Balazinski (2002). Para simular as condições de chão de fábrica, seis conjuntos de parâmetros de força (corte e avanço) foram selecionados e aplicados em seqüência. O desgaste da ferramenta foi medido após o término de cada seqüência. Verificou-se que o número de neurônios na camada oculta da RNA e o número de iterações pode ser selecionado arbitrariamente e tem pouca influência na performance do sistema, e a desvantagem do método é o considerável longo período de treinamento.

No trabalho desenvolvido por Santos (1999), foi desenvolvido um algoritmo computacional que modela as habilidades de aprendizado e tomadas de decisão do operador. Através das informações geradas pelos sensores instalados num centro de usinagem, foi acoplado ao sistema de monitoramento um sistema de tomada de decisões. Aqui se utilizou o algoritmo "Sequential Forward Search", SFS, que previamente seleciona as características mais relevantes do comportamento do espectro do sinal dos sensores (da força, corrente e aceleração). A Rede Neural Artificial é utilizada para integrar a informação das frequências selecionadas e reconhecer a ocorrência do desgaste da ferramenta numa operação de fresamento. Os sinais dos sensores foram igualmente amostrados a uma taxa de 10kHz para

uma banda de frequência de 5kHz. Durante a análise espectral dos dados obtidos notou-se que a banda de passagem do sinal poderia ser menor, ou seja, as frequências que aparentemente são influenciadas pela mudança do estado da ferramenta estariam compreendidas abaixo de 1kHz. Os sinais armazenados foram reamostrados a uma frequência de 2kHz e o tamanho do vetor de aquisição foi reduzido de 2048 para 1024 elementos. A regra de que "quanto mais característica, melhor o desempenho da RNA" nem sempre é verdadeira. Pode acontecer a degeneração das informações do processo que dizem respeito ao desgaste da ferramenta e a RNA aprender do comportamento de características que estejam sendo influenciadas por variáveis que não dizem respeito ao fenômeno de desgaste.

As Redes Neurais Artificiais são utilizadas para estimação do desgaste da ferramenta e o método de treinamento retropropagação destacou-se como o mais popular mecanismo de treinamento.

Segundo Weingaertner (2002), apesar do grande número de publicações relativas ao monitoramento de ferramentas e/ou processos de usinagem, a aplicação de sistemas de monitoramento em ambientes industriais ainda é muito reduzida e pouco confiável. Durante a década de 90, o monitoramento através de sinais de força foi dominante. Mais recentemente, a emissão acústica e a vibração têm ganhado espaço, principalmente pelo menor custo dos equipamentos e pela facilidade de instalação dos sensores.

Para a análise e processamento dos sinais, há várias técnicas de redução de dados disponíveis que podem ser utilizadas com o objetivo de extrair as características dos sinais, como o cálculo dos valores RMS (Root Mean Square), a Transformada Rápida de Fourier e a Transformada Wavelet, independentemente da quantidade de sensores utilizados na aquisição dos dados, sendo que há uma grande perspectiva na aplicação da Transformada Wavelet. Dentre os métodos para tomada de decisões, como fuzzy e lógica nebulosa, podemos destacar as Redes Neurais Artificiais, tendo em vista a sua capacidade de aprendizado por experiência, generalização a partir de exemplos anteriores e a habilidade em solucionar problemas complexos, permitindo sua aplicação nas mais diversas áreas, inclusive no monitoramento e detecção de falhas, sendo que as Redes Neurais Artificiais foram as mais bem utilizadas para a identificação das condições do sistema no processo de monitoramento. O sucesso da utilização de RNAs depende da qualidade dos dados que são utilizados no seu treinamento, ou seja, seu correto funcionamento não depende exclusivamente em grandes quantidades de dados, mas sim, em dados que possam representar as reais características do processo monitorado e que esses dados não sejam redundantes, dificultando o processo de aprendizado

da rede. Por isso, torna-se necessária a utilização de técnicas de redução de dados eficientes, capazes de representar com a menor quantidade de dados possível as características extraídas pelo sistema de monitoramento. Num futuro próximo, as características extraídas pela transformada wavelet atuando como entradas de uma Rede Neural Artificial poderão resultar em reconhecimento e classificação de falhas muito mais detalhado e confiável que os dados dos sistemas utilizados atualmente.

O levantamento bibliográfico realizado mostra que, o monitoramento do processo de usinagem tem um aspecto de grande importância para o crescimento da produção de produtos de alta qualidade em larga escala, resultando na melhor utilização da vida da ferramenta de corte e, conseqüentemente, na redução de custos. Entretanto, a determinação do momento ideal para a substituição da ferramenta ainda é o ponto chave neste contexto, pois são vários os fatores que influem no desgaste da ferramenta e a separação e extração das informações mais relevantes, para avaliação da vida da ferramenta, não é imediata. Portanto, o sucesso do monitoramento do tempo de vida da ferramenta depende da qualidade das informações extraídas dos sinais coletados e do algoritmo de inteligência computacional usado para analisá-las.

As técnicas e ferramentas de monitoramento atuais, ainda não estão totalmente desenvolvidas para a aplicação em sistemas de monitoramento em ambientes industriais, e não apresentam suficiente confiabilidade nas respostas fornecidas, devido à extensa faixa de condições operacionais e os vários fatores que afetam o desgaste da ferramenta de corte e, conseqüentemente, a aquisição e extração de características relevantes para identificação do estado da ferramenta. Os sinais e informações utilizadas podem conter informações falsas ou inadequadas para a identificação do desgaste. Isso mostra a necessidade de que novas pesquisas e trabalhos sejam realizados nesta área, permitindo uma melhoria e um avanço no desenvolvimento de sistemas de monitoramento.

Busca-se na realização deste trabalho, através de testes experimentais em diferentes condições de usinagem no processo de torneamento, fornecer uma contribuição no estudo de métodos capazes de identificar o momento mais apropriado para a substituição da ferramenta de corte, bem como, aliar a potencialidade da aplicação de Redes Neurais Artificiais em conjunto com a Transformada Wavelet.

Neste capítulo foi apresentado um levantamento bibliográfico acerca dos trabalhos e pesquisas desenvolvidos, abordando assuntos relativos a utilização de redes neurais artificiais aplicadas no monitoramento da vida de ferramentas de corte, entre outros.

Os capítulos subseqüentes têm o intuito de apresentar os fundamentos básicos, ou seja, as principais informações relativas aos conceitos envolvidos para a realização deste trabalho, abrangendo assuntos sobre os principais tipos de desgaste e avarias em ferramentas de corte, informações relativas aos métodos de monitoramento utilizados para monitorar o desgaste de ferramentas, conceitos gerais sobre redes neurais artificiais, além de discutir alguns aspectos das técnicas de redução de dados utilizadas para realçar e separar as informações relevantes do sinal.

CAPÍTULO 3

3. MONITORAMENTO DO PROCESSO DE USINAGEM

3.1. INTRODUÇÃO

O desenvolvimento de sistemas de monitoramento e controle em tempo real do processo de usinagem, com o objetivo de detectar indícios de deterioração no processo, causados principalmente pelo fim de vida da ferramenta, assim como a obtenção da usinagem não assistida e otimização dos recursos de usinagem, têm sido um desafio na área de usinagem.

A rapidez com que as mudanças acontecem na atualidade nas indústrias, principalmente do ramo metalmeccânico, têm apontado uma grande necessidade de informações confiáveis sobre desempenho da produção e informações de parâmetros tecnológicos das máquinas-ferramenta. Sistemas de apontamentos manuais mostram-se deficientes quanto a confiabilidade, velocidade de atualização, detecção de não conformidade e outros fatores prejudiciais à produção, além de gerarem redundância de trabalho na coleta e alimentação de bancos de dados. Conseqüentemente, as informações geradas a partir desses apontamentos, podem criar uma percepção diferente da realidade para os responsáveis pelas tomadas de decisões. Assim, decisões podem, muitas vezes, virem de modo não compatível com a realidade e com retardo suficiente para o agravamento da situação de deterioração do processo de usinagem, que, em determinados casos, são capazes de levar à perda total de lotes de peças produzidas.

Os sistemas de usinagem convencionais utilizam a intervenção humana para detectar anormalidades, inspecionar a qualidade do produto e controlar o processo, sendo que, os critérios para a interrupção do processo podem ser definidos de forma diferente por cada operador, e o pior, em muitas vezes estes critérios não são bem sucedidos nas rotinas de monitoramento em que são aplicados. Isso tem forçado a troca da ferramenta de corte, por exemplo, muito antes de atingir o momento adequado para a sua substituição. Por isso, o monitoramento da usinagem de materiais baseado em técnicas que permitem diminuir a intervenção do operador e substituir algumas das funções do homem na produção de bens

manufaturados por sensoriamento inteligente, é hoje uma área crescente de pesquisa, incluindo casos em ambientes reais de trabalho na indústria.

Segundo Bonifácio (1993), um dos fatores responsáveis pelo relativo insucesso para a aplicação do monitoramento em nível de chão de fábrica, é que não se chega a um consenso quanto ao sinal ou efeito da usinagem que se deve monitorar. O conhecimento de um sinal ou efeito que represente o processo global da usinagem, e que possa ser usado para uma ampla variedade de processos de usinagem, e para todo campo de aplicação, ainda é muito limitado. Em outras palavras, diferentes tipos de materiais usados na fabricação das ferramentas, diferentes condições de usinagem (velocidade de corte, profundidade de corte, avanço, etc.), diferentes materiais a serem usinados, condições diferentes das máquinas-ferramenta, dentre outros, dificultam o desenvolvimento de sistemas de monitoramento universais.

Estas dificuldades têm conduzido ao desenvolvimento de procedimentos de monitoramento para condições específicas, indicando-se um tipo de monitoramento mais adequado para cada caso.

Atualmente, muitas operações realizadas pelo homem já estão sendo realizadas pelas máquinas automatizadas (CNC, por exemplo), mas as 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 (HARA, 1995). Este capítulo busca discutir os principais aspectos envolvidos no monitoramento de ferramentas de corte.

A seguir são apresentados os fundamentos sobre ferramentas de corte, incluindo informações sobre o processo de desgaste, bem como uma discussão sobre o monitoramento e a instrumentação aplicada no processo de usinagem dos materiais.

3.2. FERRAMENTAS DE CORTE

3.2.1. DESGASTE

Existem basicamente dois grupos de falhas em ferramentas de corte: falhas contínuas e aleatórias. As falhas contínuas, de comportamento determinístico, são cumulativas e regularmente originadas a partir do desgaste de flanco e de cratera da ferramenta, e as falhas aleatórias, são associadas a inúmeras razões, tais como: desgaste excessivo, choque mecânico,

choque térmico, variações no material da peça, entre outros, e são ocasionadas geralmente pelas avarias, destacando o lascamento e a fratura (WEINGAERTNER, 2002).

O processo de desgaste da ferramenta geralmente ocorre em combinação com o modo predominante de desgaste, sendo dependente das condições de usinagem, material da peça e da geometria da ferramenta (DIMLA, 2000; DEVILLEZ et al., 2003).

O desgaste de flanco (ou frontal), ocorre na superfície de folga da ferramenta e é causado pelo contato entre a ferramenta e a peça. É o tipo de desgaste mais comum. Este tipo de desgaste ocasiona deterioração do acabamento superficial da peça e, por modificar totalmente a forma da aresta de corte original, faz com que a peça mude de dimensão, podendo inclusive sair de sua faixa de tolerância (DINIZ et al., 2000; FERRARESI, 1970).

O desgaste que ocorre na superfície de saída da ferramenta é chamado desgaste de cratera, e é causado pelo atrito entre a ferramenta e o cavaco. O cavaco desliza na superfície de saída da ferramenta se atraindo na mesma, provocando nesta superfície desgaste em baixo relevo. Nem sempre ocorre desgaste por crateramento em processos de torneamento, uma vez que é consequência do tipo de material usinado, geometria do cavaco, tipo de ferramenta, parâmetros de corte, entre outros. O crescimento do desgaste de cratera resulta na quebra da ferramenta, quando tal desgaste se encontra com o desgaste frontal. (TRENT, 1984; DINIZ et al., 2000).

A Figura 3.1 mostra o estado da ferramenta caracterizado pelo desgaste de flanco e desgaste de cratera, os quais têm uma influência dominante na vida da ferramenta.




Figura 3.1 – Regiões de desgaste da ferramenta (LIM et al., 2001)

Um outro tipo de avaria da ferramenta é conhecido como deformação plástica da aresta de corte, e pode ser causada pela pressão aplicada à ponta da ferramenta, somada a altas temperaturas, causando uma alteração dimensional que não é recuperada quando a tensão ou carga aplicada é removida da ferramenta. Tal deformação provoca deficiências do controle de cavacos e deterioração do acabamento superficial da peça. É evitada pelo emprego de uma ferramenta com maior dureza a quente e maior resistência à deformação plástica, ou pela mudança das condições de usinagem e/ou geometria da ferramenta, visando à diminuição dos esforços e da temperatura de corte (DINIZ et al., 2000).

Além dos desgastes naturais e inevitáveis nas arestas de corte da ferramenta, podemos citar outras ocorrências que prejudicam seus desempenhos, encurtando-lhes a vida, tais como: trincas, choques térmicos e ações mecânicas.

Geralmente o fluxo irregular ou repentino do líquido refrigerante e/ou variação na profundidade de corte (sobremetal com camada irregular) ocasionam os choques térmicos. As ações mecânicas, são conseqüências de cortes interrompidos ou intermitentes e paradas bruscas durante cisalhamento do cavaco. As trincas em ferramentas de corte, podem ser provocadas por choques térmicos ou ações mecânicas.

Um outro tipo de avaria da ferramenta é o lascamento, no qual partículas maiores são retiradas de uma só vez, ocorrendo principalmente em ferramentas com material frágil e/ou quando a aresta de corte é pouco reforçada.

Quando ferramentas de corte possuem alguns dos fatores como dureza elevada, carga excessiva sobre a ferramenta, raio de ponta, ângulo de ponta ou ângulo de cunha pequenos, corte interrompido e vazão deficiente do cavaco, pode ocorrer inesperadamente a sua quebra (DINIZ et al., 2000).

A Figura 3.2 ilustra os principais tipos de falhas encontradas em ferramentas de metal duro.




Figura 3.2 – Falhas em ferramentas de corte (WEINGAERTNER, 2002): (a) desgaste de flanco; (b) desgaste de cratera; (c) trincas térmicas; (d) lascamentos; (e) fratura.

Tanto as falhas de natureza regular (dependentes do tempo de uso) quanto às aleatórias (independentes do tempo), podem conduzir a ferramenta a um colapso total, resultando em sua quebra, conforme observado na Figura 3.2e.

Segundo Ferraresi (1970) e Diniz et al. (2000), há outros fenômenos causadores dos desgastes das ferramentas, como a Aresta Postiça de Corte (APC), Abrasão Mecânica, Aderência e Difusão.

A Figura 3.3 mostra o efeito da aresta postiça de corte, no processo de usinagem. Neste caso, ela tende a crescer gradualmente até que em um certo momento ela se rompe bruscamente, causando uma perturbação dinâmica no processo. Parte da aresta postiça que se rompe é carregada com o cavaco e parte adere à peça, prejudicando sensivelmente o acabamento superficial da mesma. Ao se romper, a aresta postiça arranca partículas da superfície de folga da ferramenta, gerando um desgaste frontal muito grande, mesmo em velocidades de corte baixas (FERRARESI, 1970; DINIZ et al., 2000)




Figura 3.3 – Aresta postiça de corte (DINIZ et al., 2000)

A abrasão mecânica é decorrente do processo de fricção ou atrito entre a ferramenta e a peça, removendo progressivamente parte da superfície da ferramenta, sendo uma das principais causas de desgaste. Tanto o desgaste frontal quanto o desgaste de cratera podem ser gerados pela abrasão, porém ela se faz mais proeminente no desgaste frontal, já que a superfície de folga atrita com um elemento rígido que é a peça, enquanto que a superfície de saída atrita com um elemento flexível que é o cavaco. O desgaste gerado pela abrasão é incentivado pela presença de partículas duras no material da peça e pela temperatura de corte, que reduz a dureza da ferramenta (FERRARESI, 1970; DINIZ et al., 2000; DEVILLEZ et al., 2003).

O desgaste por aderência, ocorre quando duas superfícies metálicas são postas em contato sob cargas moderadas, baixas temperaturas e baixas velocidades de corte, em que se forma entre as superfícies um extrato metálico que provoca a aderência. A resistência deste extrato é elevada a tal ponto que, na tentativa de separar as superfícies, ocorre ruptura em um

dos metais e não na superfície de contato. Assim partículas da superfície de um metal migram para a superfície do outro. O fenômeno da aderência está presente na formação da aresta postiça de corte, mas pode-se ter desgaste por aderência mesmo sem a formação da aresta postiça. Esse fenômeno também é importante na formação do desgaste de entalhe (FERRARESI, 1970; DINIZ et al., 2000; DEVILLEZ et al., 2003).

O desgaste por difusão ocorre pela transferência de elementos químicos entre a ferramenta e o material retirado da peça, segundo o qual materiais diferentes se misturam como resultado do movimento dos seus elementos químicos. Um exemplo típico de desgaste por difusão é aquele que acontece na ferramenta de diamante quando se usina ligas ferrosas. Este fenômeno causa uma cratera na superfície da ferramenta, o qual reduz as propriedades mecânicas da ferramenta. Assim, em altas velocidades de corte, a difusão transforma-se no principal mecanismo de desgaste, pois é na superfície de saída da ferramenta que se tem as condições necessárias para a difusão, isto é, alta temperatura (devido às altas velocidades e à zona de aderência) e tempo de contato cavaco-ferramenta (devido à zona de aderência, onde a velocidade de saída do cavaco é zero) (FERRARESI, 1970; DINIZ et al., 2000; DEVILLEZ et al., 2003)..

3.2.2. VIDA DA FERRAMENTA

Vida da ferramenta é o tempo que a mesma trabalha efetivamente (deduzidos os tempos passivos), até perder sua capacidade de corte, dentro de um critério previamente estabelecido. Atingido este tempo, a ferramenta deve ser reafiada ou substituída (FERRARESI, 1970).

O monitoramento em tempo real da condição da ferramenta é um importante passo para prevenir danos à peça e a ferramenta, e incrementar o efetivo tempo de utilização da ferramenta. Entretanto, o critério de fim de vida da ferramenta adotado é um problema básico no monitoramento das condições da ferramenta.

O fim da vida da ferramenta, diferentemente da falha total da ferramenta que acontece quando há uma completa destruição da aresta de corte, devido ao crescimento dos desgastes ou a uma avaria da ferramenta (quebra ou trinca, por exemplo), ocorre quando a mesma não desempenha mais as funções a que ela se destina (BONIFÁCIO, 1993), com as mesmas características, isto é, existe uma perda de eficiência ou qualidade da peça, que compromete o processo

A literatura discute vários critérios para o fim de vida da ferramenta os quais dependem de várias considerações. Basicamente estes critérios podem ser definidos com base na falha da ferramenta (incluindo a fratura, trinca e desgaste acelerado), tolerância dimensional da peça, rugosidade da peça e considerações econômicas.

O desgaste de flanco é usualmente escolhido como referência para o critério de fim de vida da ferramenta sob condições normais de usinagem (ZHOU et al., 1995). Outros critérios ou mesmo a combinação de vários critérios também são utilizados.

Diniz et al. (2000), por exemplo, definem que uma ferramenta de usinagem deve ser substituída quando um ou mais dos fatores abaixo (critérios de fim de vida) acontecerem:

- a) os desgastes atingirem proporções tão elevadas que se receie a quebra da aresta de corte;
- b) não for mais possível a obtenção de tolerâncias apertadas e/ou bons acabamentos superficiais da peça devido ao desgaste;
- c) os desgastes crescerem muito, fazendo com que a temperatura da aresta cortante ultrapasse a temperatura na qual a ferramenta perde o fio de corte (a aresta de corte se decompõe);
- d) o aumento da força de usinagem, proveniente dos desgastes elevados da ferramenta, interfere no funcionamento da máquina.

Em processos de torneamento em acabamento, em que o desgaste da ferramenta não chega a atingir valores em que se receia a quebra da mesma e o crescimento da força de usinagem também não chega a comprometer o funcionamento da máquina, o que determina o fim de vida da ferramenta é a precisão e/ou a rugosidade da peça (BONIFÁCIO, 1993). Quando a dimensão da peça começa a sair da faixa de tolerância dimensional exigida, ainda se tem o recurso de reposicionar a ferramenta, de modo que o corte consiga produzir uma peça com tolerância desejada. Assim, monitorar a rugosidade da peça é uma boa alternativa para se estabelecer com precisão o fim da vida da ferramenta.

3.3. MÉTODOS DE MONITORAMENTO

As técnicas para monitoramento do desgaste podem ser agrupadas em duas grandes categorias: **métodos diretos** e **métodos indiretos** (DAN et al., 1990).

Os **métodos diretos** medem diretamente a variável a ser monitorada, por exemplo, a dimensão da peça ou o monitoramento óptico do desgaste da ferramenta. Esses métodos não apresentam interferências de outros parâmetros. Por outro lado são muito difíceis de serem aplicados na prática, pois, em geral não se consegue fazer as medições enquanto o processo está acontecendo (tempo real), por limitações tecnológicas. Os sensores utilizados (câmeras de tv, transdutores, etc), geralmente são mais caros.

Nos **métodos indiretos**, um ou mais parâmetros são controlados e monitorados em tempo real e, posteriormente, correlacionados com os parâmetros que realmente influem no desgaste da ferramenta. Neste caso, as medidas podem ser influenciadas por fatores alheios ao desgaste: variações no material de trabalho, geometria da ferramenta de corte, vibrações do sistema, força de corte, emissão acústica, etc., que afetam o monitoramento. Tem como principal característica a sua fácil aplicação e pouca interferência no processo, pois se pode utilizar equipamentos de dimensões reduzidas, e em muitos casos, mede-se um sinal ou efeito remotamente, ou seja, distante da zona de usinagem. (DAN et al., 1990).

No processo de monitoramento o operador procura acompanhar qualquer variação das condições de operação da máquina e atuar no processo quando esta começa interferir na qualidade da usinagem ou sinaliza indícios de um possível dano do sistema.

As principais características desejáveis de um bom sistema de monitoramento incluem confiabilidade, baixo custo, simplicidade, capacidade de suportar o ambiente industrial e não ser influenciado por ruídos externos. O parâmetro medido deve ser dependente somente da variável desejada (o que se quer monitorar), o sistema deve ser pouco intrusivo e apresentar um tempo de resposta baixo, ou seja, o sensor deve ser suficientemente rápido para responder as variações do sistema e não deve interferir na operação de usinagem (MATSUMOTO, 1998).

A tabela 3.1 classifica e caracteriza alguns dos principais métodos de monitoramento.

Tabela 3.1 – Métodos de monitoramento (DAN et al., 1990)

Métodos	Processo	Medida	Sensor
<i>DIRETOS</i>	Óptico	Forma ou posição da ponta da ferramenta	Câmera de TV
	Desgaste de partículas e radioatividade	Tamanho de partículas e radioatividade	Espectrofotômetro, medidores de radioatividade
	Resistência da junção peça/ferramenta	Variação da resistência da junção	Voltímetro
	Dimensão da peça	Dimensão da peça	Micrômetros e transdutores eletromagnéticos
<i>INDIRETOS</i>	Força de usinagem	Variação da força de usinagem	Dinamômetros
	Emissão acústica	Pressão da onda de energia	Transdutores piezoelétricos de emissão acústica
	Som	Ondas acústicas	Microfone
	Vibração	Vibração na interface peça-ferramenta	Acelerômetro
	Temperatura	Variação de temperatura da ferramenta	Termopares, pirômetros, etc.
	Potência do motor principal ou de avanço	Potência ou corrente	Amperímetros, voltmíetros, etc.
	Rugosidade	Variação da rugosidade da superfície	Transdutor óptico, rugosímetro.

3.4. COMPONENTES DE UM SISTEMA DE MONITORAMENTO

Os sistemas de monitoramento indireto, notadamente contêm características semelhantes e usualmente consistem em três etapas básicas. A primeira etapa consiste em coletar os sinais monitorados, tais como força, vibração, emissão acústica, temperatura, e/ou corrente do motor. A segunda etapa consiste em processar os sinais, para obter um conjunto de dados referentes às características monitoradas. A última etapa consiste na classificação, nesta fase, as características extraídas do monitoramento são utilizadas para classificação da

condição atual da ferramenta, com base em uma condição predefinida da ferramenta (SCHEFFER, 2003).

De acordo com Tönshoff et al. (1988), os principais componentes de um sistema de monitoramento e controle são:

- □ Sensor;
- □ Condicionador do sinal;
- □ Modelo;
- □ Estratégia.

3.4.1. SENSORES

São os elementos que realizam a medição do parâmetro desejado e o transforma, geralmente, em sinal elétrico.

Um sensor deve apresentar as seguintes características:

- □ Ser confiável – que significa dependência do parâmetro que se deseja medir e o parâmetro que está sendo monitorado e repetibilidade da performance do sensor em ambientes reais, isto é, ambientes de fábricas.
- □ Ser simples e barato.
- □ Ser não intrusivo – não deve ser um sensor grande, com vários cabos elétricos colocado perto da região de corte, o que tornaria impossível a sua utilização em casos reais.
- □ Deve suportar o ambiente industrial.
- □ Não deve ser influenciado por ruídos externos - como vibração do motor da máquina, quebra do cavaco, etc.

3.4.2. CONDICIONAMENTO DO SINAL

Esta etapa é fundamental no processo de monitoramento, visto que o sinal do sensor pode conter informações espúrias, que necessitam serem expurgadas do processo, além de permitir que o sinal de interesse seja transmitido de forma correta e confiável para os equipamentos de medição.

Os sinais elétricos de saída do sensor, para que possam ser aproveitados na tarefa de monitoramento do processo, devem ser amplificados, filtrados, eventualmente convertidos de

analógico para digital e armazenados na memória do computador, para uma posterior análise ou para controle do processo.

3.4.3. MODELOS PARA EXTRAÇÃO DE INFORMAÇÕES RELEVANTES (*SIGNAL FEATURES*)

A análise dos sinais coletados pode ser feita no domínio do tempo, no domínio da frequência ou no domínio do tempo-frequência, com a finalidade de verificar o comportamento deste sinal. No domínio do tempo, os sinais podem ser analisados através de parâmetros estatísticos como média, valor médio quadrático (RMS) e desvio padrão, no domínio da frequência, através da Transformada Rápida de Fourier (*Fast Fourier Transform* – FFT), sendo que as informações podem ser picos de amplitudes e bandas de frequência, energia, e no domínio do tempo-frequência, utilizando-se a Transformada Wavelet. Em qualquer dos casos, o que se procura é a definição de um modelo que represente fielmente o sistema de interesse, ou no caso da análise e o processamento de sinais, técnicas de identificação capazes de ressaltar as características importantes para avaliação da evolução da vida da ferramenta.

3.4.4. ESTRATÉGIA

A partir de informações obtidas com o monitoramento, como por exemplo a medição das forças de corte ou níveis de vibração, pode-se detectar alguma falha no processo, como o desgaste ou quebra da ferramenta, sendo que o sistema pode tomar as seguintes decisões:

- □ Indicar alguma informação em vídeo;
- □ Ativar um alarme;
- □ Diagnosticar o problema e sugerir solução;
- □ Parar imediatamente o processo, se alguma emergência ocorrer, como a quebra da ferramenta.

3.5. INSTRUMENTAÇÃO APLICADA AO MONITORAMENTO DA VIBRAÇÃO

Uma montagem típica de um sistema experimental de monitoramento, via vibração, é ilustrada na Figura 3.4.

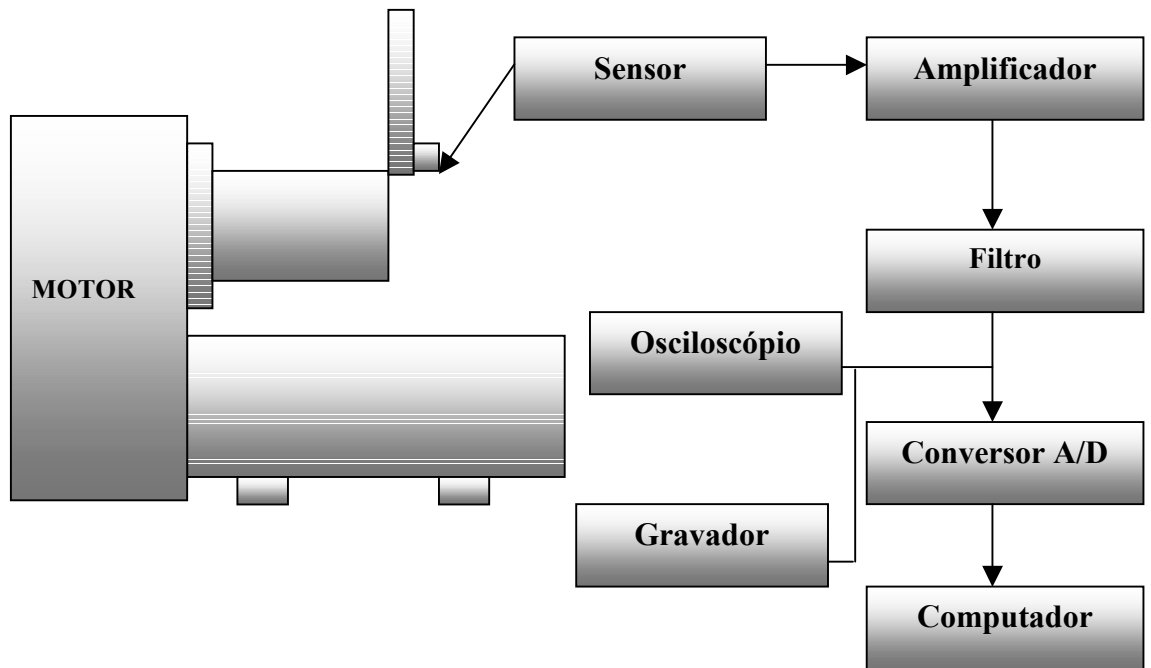


Figura 3.4 – Esquema de montagem do sistema de monitoramento (HARA, 1995).

Apresenta-se aqui, um breve comentário de acordo com HARA (1995) acerca de alguns dos componentes utilizados no monitoramento.

- □ Sensor (Acelerômetro piezoelétrico – sensor de vibração) – tem 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, e que é uma indicação da vibração instantânea deste corpo.
- □ Amplificador – tem por finalidade amplificar os sinais de saída dos sensores.
- □ Filtros – frequências de interesse do sinal são, muitas vezes, restritas a uma determinada faixa, e os filtros têm por finalidade possibilitar a eliminação das componentes dos sinais fora dessa faixa. Os filtros geralmente são classificados em três categorias: passa baixa, passa alta e passa banda
- □ Osciloscópio – permite acompanhar visualmente a variação do sinal.

- □ Conversor A/D – é uma placa de expansão que permite integrar o uso de microcomputadores ao meio ambiente externo. Essas placas permitem a interface entre os microcomputadores e os diversos sinais existentes externamente, sejam estes sinais analógicos ou digitais, permitindo a utilização de microcomputadores nos mais variados campos.
- □ Gravador – utilizado para armazenamento e gravação do sinal bruto, para possibilitar a análise posterior dos sinais e um estudo mais detalhado do processo, já que se pode gravar os sinais de vibração de todo o processo.
- □ Microcomputador – grava os dados, analisa o sinal, etc.

CAPÍTULO 4

4. REDES NEURAIS ARTIFICIAIS

4.1. INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) tiveram origem com base no estudo e desenvolvimento de sistemas simulando a estrutura biológica e o trabalho do cérebro humano. McCulloch e Pitts foram os primeiros a estudar acerca do assunto em 1943. Desde então, o número de estudos tem crescido consideravelmente (TOSUN et al., 2002).

As primeiras informações mencionadas datam de 1943, em artigos de McCulloch e Pitts, em que sugeriam a construção de uma máquina baseada ou inspirada no cérebro humano. Em 1949, Donald O. Hebb formula a primeira lei de aprendizagem que marca o ponto de partida para os algoritmos de treinamento de RNAs.

Nas décadas de 1950 e 1960, um grupo de pesquisadores produziu a primeira rede neural artificial. Em 1958, Frank Rosenblatt, desenvolveu redes consistindo de uma simples camada de neurônios artificiais, chamadas de *perceptron*. Essas redes foram aplicadas em diversos problemas como previsão do tempo, análise de eletrocardiogramas e visão artificial. Em 1960, surgiu a rede ADALINE (*Adaptive Linear Network*) e a MADALINE (*Multi ADALINE*), proposta por Widrow e Hoff. Parecia que a chave da inteligência havia sido encontrada.

Essa ilusão foi logo dissipada. As redes falharam em resolver problemas superficialmente semelhantes àqueles que tiveram sucesso na resolução. Em 1969, Minsky e Papert provaram que uma rede de simples camada, não era capaz de resolver muitos problemas simples, incluindo o problema do “ou-exclusivo” (XOR).

Um período de pesquisa silenciosa seguiu-se durante os anos seguintes até 1982, quando poucas pesquisas foram publicadas devido aos fatos ocorridos anteriormente. Entretanto, aqueles que pesquisavam nesta época, e todos os que se seguiram no decorrer destes anos, conseguiram novamente estabelecer um campo concreto para o renascimento da área.

As redes neurais artificiais tiveram seu reconhecimento recuperado através do físico Jonh Hopfield, que, em 1982, usou a idéia de uma função de energia para formular uma nova maneira de entender os cálculos feitos pelas redes recorrentes com conexões de sinapse simétricas. Esta particular classe de redes neurais com *feedback*, atraiu grande atenção nos anos 80, e com o tempo tornou-se conhecida como redes de Hopfield.

Em 1986, Rumelhart, Hinton e Willian, propuseram um modelo chamado *Backpropagation*, que ampliava o potencial do perceptron, provendo uma maneira sistemática para o treinamento de redes multicamadas, de modo a permitir a superação das limitações do modelo primitivo.

A seguir são discutidas as principais características das RNAs, estrutura dos neurônios biológicos e artificiais, RNAs simples e multicamadas, regras de treinamento, entre outros.

4.2. NEURÔNIO BIOLÓGICO

O corpo humano consiste em trilhões de células. Uma parte dessas células são as células nervosas, chamadas “neurônios”. Estes neurônios têm diferentes formas e tamanhos, e são produzidos especialmente para conduzir informações via eletroquímica.

O sistema nervoso humano é surpreendentemente complexo. Estima-se que 10^{11} neurônios participam do sistema, estabelecendo em torno de 10^{15} interconexões de caminhos de transmissão. Cada neurônio compartilha muitas características com outras células no corpo, mas tem uma única capacidade de receber, processar e transmitir sinais eletroquímicos sobre as vias que constitui o sistema de comunicação do cérebro (WASSERMAN, 1989).

Um neurônio biológico é composto de um corpo, que contém um núcleo e dois tipos de extensão chamados de “dendritos” e “axônios”. O núcleo é localizado no centro do neurônio e fornece energia para as atividades celulares. Um neurônio é conectado a outros neurônios através dos axônios e dendritos. Os canais que trazem impulsos para a célula nervosa são chamados **dendritos**, os canais que conduzem impulsos para outras células são chamados **axônios**. Os dendritos recebem os impulsos por contato com outros neurônios e conduzem esses impulsos para o núcleo. O impulso que sai do núcleo é conduzido via axônio e esta operação é repetida continuamente. O ponto de conexão entre dois neurônios é chamado **sinapse** (WASSERMAN, 1989).

A Figura 4.1 ilustra a estrutura do neurônio biológico.

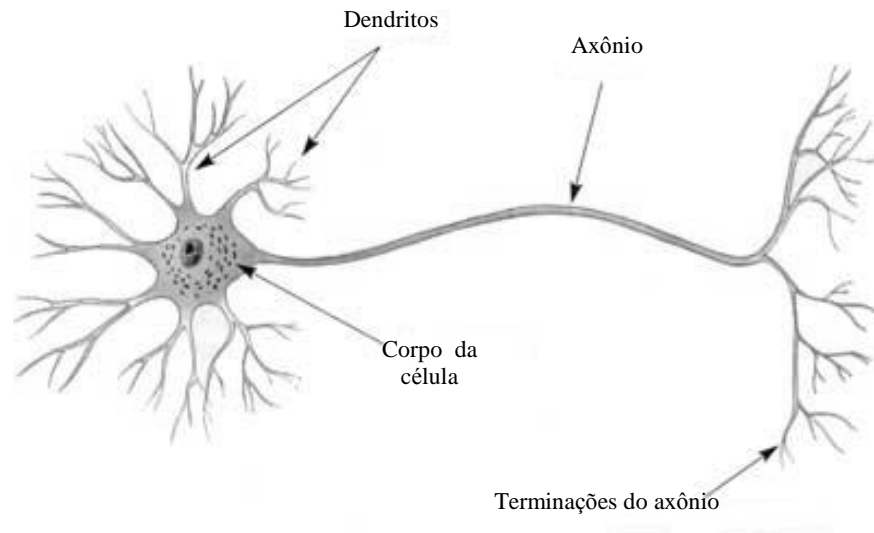


Figura 4.1 – Neurônio biológico (WASSERMAN, 1989)

4.3. NEURÔNIO ARTIFICIAL

O elemento básico de uma RNA é o neurônio artificial, também conhecido como elemento de processamento (BERNIERI et al., 1994). Em resumo, um conjunto de entradas é aplicado, representando cada saída para outro neurônio. Cada entrada é multiplicada por um peso correspondente, análoga a força sináptica, e todos os pesos de entrada são então somados para determinar o nível de ativação do neurônio. A Figura 4.2 mostra o modelo que implementa esta idéia.




Figura 4.2 – Neurônio artificial (WASSERMAN, 1989)

Uma série de entradas denominadas x_1, x_2, \dots, x_n é aplicada ao neurônio artificial. Estas entradas, referenciadas coletivamente como um vetor X , corresponde aos sinais nas sinapses do neurônio biológico. Cada sinal é multiplicado por um peso associado w_1, w_2, \dots, w_n , antes de ser aplicado ao bloco de somatório, chamado Σ . Cada peso corresponde a “força” de uma conexão sináptica biológica simples.

O bloco somatório corresponde aproximadamente ao corpo da célula biológica, adiciona todos os pesos de entrada algebricamente, produzindo uma saída chamada NET. Na forma mais compacta (notação de vetor), a saída é dada pela equação (1) (WASSERMAN, 1989).

$$\text{NET} = XW \quad (1)$$

4.4. FUNÇÕES DE ATIVAÇÃO

A saída NET é usualmente processada por uma função de ativação F, para gerar a saída do neurônio, OUT.

Conforme ilustrado na Figura 4.3, o bloco denominado F recebe a saída de NET e produz o sinal OUT.





Figura 4.3 – Neurônio artificial com função de ativação (WASSERMAN, 1989)

Em geral, a função de ativação utilizada é a função logística ou a função sigmoidal, mostrada na Figura 4.4a e dada pela equação (2) (WASSERMAN, 1989).

$$\text{OUT} = 1 / (1 + e^{-\text{NET}}) \quad (2)$$

Uma outra função de ativação, geralmente utilizada, é a tangente hiperbólica, ilustrada na Figura 4.4b e dada pela equação (3).

$$\text{OUT} = \tanh(x) \quad (3)$$



a) Função de ativação sigmoideal;

b) Função de ativação tangente hiperbólica

Figura 4.4 – Funções de ativação (WASSERMAN, 1989)

Como a função logística, a função tangente hiperbólica é da forma de S, e é simétrica em relação à origem. Quando NET é zero, a função tangente hiperbólica passa em OUT no valor zero, como mostrado na Figura 4.4b. Diferentemente da função logística, a função tangente hiperbólica tem um valor bipolar para OUT.

4.5. RNAS DE SIMPLES CAMADAS

Segundo Wasserman (1989), a rede mais simples é formada por um grupo de neurônios organizados em uma única camada, como mostrado no lado direito da Figura 4.5. Note que os nós circulares a esquerda serve apenas para distribuir as entradas. Eles não executam cálculos e, conseqüentemente, não constituem uma camada. Por esta razão, são mostrados como círculos para distingui-los dos neurônios que efetuam cálculos, os quais são mostrados como quadrados.

O conjunto de entradas $\{X\}$ tem cada um dos seus elementos conectados a cada um dos neurônios artificiais ponderados por $w_{m,n}$. Cada neurônio emite uma soma ponderada das entradas para a rede.

É conveniente considerar os pesos como sendo elementos de uma matriz W . As dimensões da matriz são m linhas por n colunas, onde m é o número de entradas e n é o número de neurônios.




Figura 4.5 – Rede neural simples camadas (WASSERMAN, 1989)

4.6. RNAs MULTICAMADAS

Em geral, redes mais complexas oferecem maior capacidade computacional. As redes de multicamadas são providas de capacidade além daquela das redes simples camadas e, nos últimos anos, diferentes algoritmos têm sido desenvolvidos para treiná-las.

As Redes Neurais Artificiais multicamadas podem ser formadas por um grupo de RNAs Simples Camadas em cascata, onde a saída de uma camada fornece os dados de entrada da camada subsequente (WASSERMAN, 1989), conforme mostrado na Figura 4.6.

As redes multicamadas não incrementaram o poder computacional em relação as redes simples camadas, a não ser que haja uma função de ativação não linear entre as camadas. O cálculo da saída de uma camada consiste em multiplicar o vetor de entrada pela primeira

matriz contendo os pesos, e então multiplicar o vetor resultante pela segunda matriz com os pesos.

Isso pode ser expresso da forma

$$(XW_1)W_2$$

os termos podem ser reagrupados e escritos como

$$X(W_1W_2)$$

Isso mostra que uma rede com duas camadas, com função de ativação linear, é exatamente equivalente a uma rede simples camada com uma matriz peso sendo igual ao produto de duas matrizes contendo os pesos. Portanto, qualquer rede neural multicamada linear pode ser substituída por uma rede simples camada equivalente.

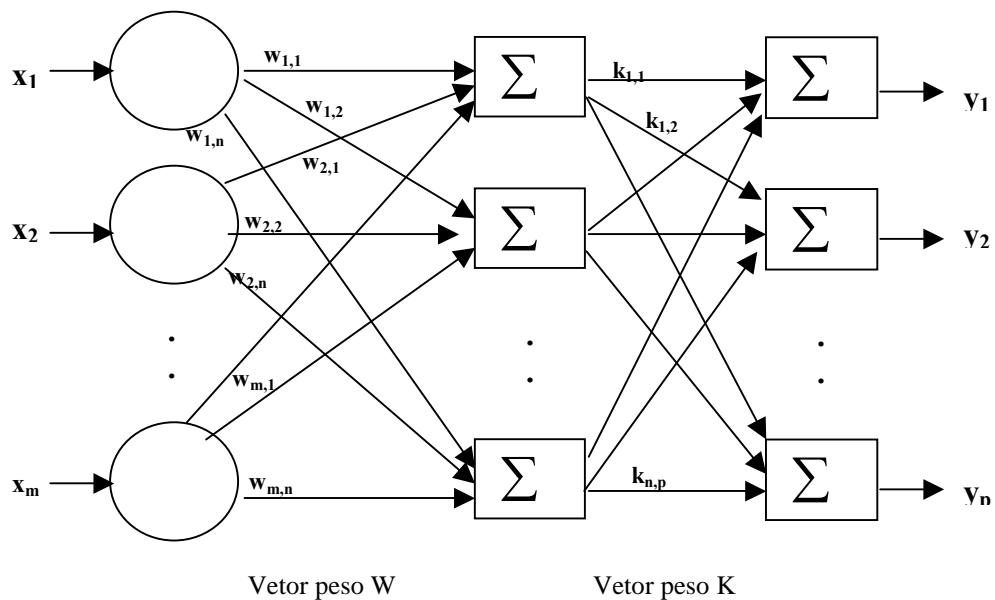


Figura 4.6 – Rede neural duas camadas (WASSERMAN, 1989)

4.7. TREINAMENTO

O treinamento bem sucedido das redes neurais artificiais representa um importante passo no processo de reconhecimento de padrões.

Denomina-se algoritmo de treinamento a um conjunto de regras bem definidas para a solução de um problema de identificação. Atualmente, existem muitos tipos de algoritmos de treinamento, inclusive alguns algoritmos específicos para determinados modelos de redes neurais. Os algoritmos, de forma geral, diferem entre si pelo modo como os pesos são modificados durante o processo de solução do problema de identificação.

O aprendizado das redes neurais artificiais é considerado como o processo de determinação dos coeficientes de ponderação (pesos) do algoritmo, de maneira que a rede possa implementar a função desejada. O processo de treinamento de uma rede neural pode ser dividido em duas categorias: aprendizado supervisionado e aprendizado não supervisionado.

O **aprendizado supervisionado** requer para cada vetor de entrada um vetor alvo, representando a saída desejada; juntos esses vetores são chamados de par de treinamento. Durante o treinamento, um estímulo de entrada é aplicado e isso resulta em uma reação de saída. Esta reação é comparada com o sinal de saída desejado. Se a saída atual diferenciar da saída desejada, o algoritmo gera um sinal de erro, que é então utilizado no ajuste dos pesos para que a saída atual seja corrigida, de forma alcançar a saída desejada ou meta. Em outras palavras, o erro é minimizado iterativamente em um processo de minimização de erro que requer um circuito especial como um professor ou supervisor, por isso o nome aprendizagem supervisionada (WASSERMAN, 1989). Se o erro não for suficientemente pequeno, o processo é repetido iterativamente até se obter um erro menor do que um valor específico pré-fixado e, então, finaliza-se o aprendizado. Um dos algoritmos mais difundidos para treinamento deste tipo de rede é o algoritmo retropropagação (“*backpropagation*” no idioma inglês).

O **aprendizado não-supervisionado** não requer o estabelecimento de um vetor alvo para as saídas e, conseqüentemente, também não requer comparações com saídas pré-determinadas, ele utiliza apenas um vetor de entrada. Neste caso, o algoritmo de treinamento modifica os pesos da rede para produzir vetores de saída consistentes. O processo de treinamento, por essa razão, extrai as propriedades estatísticas do grupo de treinamento e agrupa os vetores similares em classes. Aplicando um vetor de uma dada classe, esta entrada produzirá um vetor de saída específico, mas não há como determinar, a priori, qual padrão de

saída específico será produzido por uma dada classe de vetor de entrada. Conseqüentemente, as saídas da rede devem, geralmente, ser transformadas em formas compreensíveis para o processo de treinamento (WASSERMAN, 1989).

Em contraste com a aprendizagem supervisionada, a aprendizagem não-supervisionada não requer um professor, isto é, não há alvo de saída. Ainda que a aprendizagem não-supervisionada não requeira um professor, ela necessita de princípios gerais para determinar como formar-se-ão os grupos. O agrupamento pode ser baseado em forma, cor, consistência material ou sob alguma outra propriedade do objeto. Portanto, se os princípios gerais não foram dados, e nem os tipos de características que devem ser usadas para o agrupamento dos objetos, a aprendizagem não-supervisionada pode ou não ser bem sucedida (WASSERMAN, 1989).

4.8. REGRAS DE TREINAMENTO

Muitos dos algoritmos de treinamento atuais envolvem os conceitos de Hebb¹. Hebb propôs um modelo de aprendizado não supervisionado em que a força sináptica (peso) era incrementada se os neurônios de origem e destino fossem ativados. Neste caso, as RNAs que utilizam o aprendizado Hebbiano, tem como característica que os pesos são incrementados de acordo com o produto dos níveis de excitação dos neurônios de origem e destino (WASSERMAN, 1989).

A regra delta foi uma inovação introduzida por Widrow (1959) para o treinamento de redes do tipo ADALINE, que são compostas por uma unidade de processamento com função de transferência linear, por isso o nome ADALINE (*ADaptive LINear Element*). Este modelo foi posteriormente estendido para o caso de redes multicamadas denominadas MADALINE (*Multi ADALINE*). Em seguida, a regra delta foi adaptada para outros tipos de redes neurais, formando a base de um dos tipos de redes mais empregado atualmente, as redes multicamadas com retropropagação do erro (*Backpropagation*).

Na regra delta o treinamento da rede é feito utilizando saídas contínuas, diferentemente do *perceptron* que utiliza valores de saída binários. O algoritmo de aprendizado do perceptron pode ser resumido como:

¹ Donald O. Hebb – Em 1949 propôs uma lei de aprendizagem que tornou-se o ponto de partida para os algoritmos de treinamento das redes neurais artificiais.

1. Aplicar uma entrada e calcular a saída Y ;
2.
 - a. Se a saída estiver correta, vá para o passo 1;
 - b. Se a saída estiver incorreta, e for zero, adicionar a cada entrada o peso correspondente; ou
 - c. Se a saída estiver incorreta e for um, subtraia de cada entrada o peso correspondente;
3. Vá para o passo 1.

A generalização do algoritmo de treinamento do *perceptron*, levou à chamada **regra δ** , que estende a técnica para entradas e saídas contínuas. Neste caso, o passo 2 do algoritmo anterior pode ser reestruturado e generalizado introduzindo um termo δ , que é a diferença entre a saída desejada D e a saída atual A ,

$$\delta = (D - A) \quad (4)$$

Para o caso $\delta = 0$, a saída é correta e não são necessários cálculos adicionais, e para $\delta > 0$ e $\delta < 0$ a saída é incorreta. Em qualquer caso, o algoritmo é satisfeito se δ é multiplicado pelo valor de cada entrada x_i e este produto é adicionado ao peso correspondente. Generalizando, define-se uma “taxa de aprendizagem” representada pelo coeficiente η , que multiplica o produto δx_i . Isso permite o controle do tamanho médio da mudança dos pesos (WASSERMAN, 1989),

$$\Delta_i = \eta \delta x_i \quad (5)$$

$$w_i (n + 1) = w_i (n) + \Delta_i \quad (6)$$

sendo:

Δ_i : correção associada com a i -ésima entrada x_i ;

$w_i (n + 1)$: valor de ponderação i após o ajuste;

$w_i (n)$: valor de ponderação i antes do ajuste.

A diferença básica do algoritmo de treinamento da rede ADALINE em relação ao *perceptron*, que utiliza valores de saída binários, é que esta utiliza uma saída contínua (WASSERMAN, 1989).

4.9. ALGORITMO BACKPROPAGATION

O algoritmo de retropropagação “*Backpropagation*” foi criado para generalizar o controle instruído por Widrow e Hoff para redes de trabalho MADALINE (múltiplas camadas), ou seja, ele é utilizado para o ajuste dos pesos e dos “*bias*” da rede. A idéia do *Backpropagation* é determinar os erros das camadas ocultas a partir do erro propagado na ordem inversa das unidades de saída.

O algoritmo de treinamento *backpropagation* consiste na apresentação de um conjunto de dados de entrada, que podem ser oriundos da camada de entrada ou da camada anterior da rede, sendo que, cada uma das entradas é multiplicada por um peso, e os produtos são somados, resultando no termo chamado NET, que deve ser calculado para cada neurônio da rede. Depois de efetuado o cálculo NET, é aplicada uma função de ativação F para modificá-lo, produzindo desse modo o sinal OUT.

A Figura 4.7 ilustra o neurônio artificial usado como referência para a implementação de redes utilizando o algoritmo *backpropagation*.




Figura 4.7 – Neurônio artificial com função de ativação $1/(1 + e^{-NET})$ (WASSERMAN, 1989)

Os valores NET e OUT, mostrados na Figura 4.7, são dados, respectivamente, pelas equações (7) e (8).

$$\text{NET} = x_1 w_1 + x_2 w_2 + \dots + x_n w_n = \sum_{i=1}^n x_i w_i \quad (7)$$

$$\text{OUT} = F(\text{NET}) = 1/(1 + e^{-\text{NET}}) \quad (8)$$

A função F, chamada função sigmoïdal ou logística, resulta a saída OUT em valores entre zero e um.

O objetivo do treinamento da rede é ajustar os pesos para que a aplicação de um conjunto de entradas produza um conjunto de saída desejadas. As entradas e saídas podem ser referenciadas como um vetor. No treinamento assume-se que, além de cada vetor de entrada, é necessário ter um vetor meta, representando a saída desejada. Esses vetores são chamados par de treinamento. Antes de iniciar o processo de treinamento, todos os pesos devem ser iniciados com valores aleatórios. A seguir são apresentadas as principais fases do processo de treinamento:

1. **Apresentação do conjunto de treinamento** – submete-se à RNA um conjunto de treinamento (par de treinamento), apresentando o vetor de entrada na camada de entrada da rede;
2. **Cálculo da saída da RNA** – as entradas são propagadas através da RNA, segundo as funções de rede e de transferência dos neurônios, e calculada a saída da RNA;
3. **Cálculo do erro** – realiza-se o cálculo do erro entre a saída da rede e a saída desejada (vetor meta do par de treinamento);
4. **Atualização dos pesos** – os pesos da rede são ajustados de modo a minimizar o erro obtido;
5. **Repetição do processo** – o processo é repetido a partir do primeiro passo, para cada vetor do conjunto de treinamento, até que o erro obtido pela rede esteja abaixo de um valor pré-determinado.

Uma das vantagens da RNA é que esta pode capturar muitos tipos de informações, que permitem o usuário explicar com maior rapidez e facilidade os problemas que, por outro lado, poderiam ser difíceis ou impossíveis de serem resolvidos. Dentre outras utilizações das RNAs, pode-se citar a inferência de múltiplas variáveis, a grande tolerância à falhas, o modelamento direto do problema e o paralelismo inerente.

Assim como nos demais casos, o sucesso da capacidade de reconhecimento e classificação das RNAs está fortemente relacionado com a qualidade dos dados utilizados no processo de treinamento (SANTOS, 2000; TOMKIEWICZ, 2001), de forma que a definição dos dados utilizados no treinamento é uma fase tão importante como o próprio treinamento da rede. Os dados usados no treinamento da rede devem ser suficientes ricos (conter todas as informações importantes para a identificação do problema) em informações, evitando informações redundantes ou espúrias (ruídos).

Os dados utilizados no treinamento da rede, geralmente, sofrem um pré-processamento que é feito utilizando técnicas de redução de dados, as quais visam excluir essas informações redundantes e evidenciar as informações importantes para a identificação do problema.

4.10. TÉCNICAS DE REDUÇÃO DE DADOS

O desenvolvimento e utilização de novas máquinas operatrizes automatizadas, sobretudo para minimizar falhas operacionais de usinagem, que podem causar a parada imediata do sistema de operação, é uma nova realidade no processo de usinagem. Isso tem criado novas exigências relacionadas ao desempenho e confiabilidade de produção, crescendo a necessidade de monitorar as máquinas e equipamentos envolvidos no processo.

Os dados obtidos num sistema de monitoramento, por exemplo, os sinais de vibração adquiridos por um sensor, podem ser tratados por diferentes técnicas de processamento de sinais, algumas mais adequadas ou não a determinadas classes de sinais (estacionário e não-estacionário).

No caso de sinais não-estacionários, provenientes de máquinas e equipamentos, muitas destas técnicas não são adequadas, visto que não são sensíveis a eventos transitórios, e mesmo as que são sensíveis, são incapazes de classificar eventos transitórios de fontes distintas. Uma alternativa é utilizar técnicas de processamento de sinais juntamente com métodos menos subjetivos de interpretação, como as redes neurais artificiais.

Um problema crítico na utilização das técnicas de processamento de sinais acopladas com redes neurais, é a grande quantidade de dados produzidos no processamento dos sinais. Embora existam RNAs que possam processar os dados temporais diretamente, a utilização de técnicas de redução de dados, ou seja, a redução dos dados que serão utilizados como entrada (padrão de entrada) da rede neural, num conjunto de dados que contenha apenas as principais informações do sinal, é um ponto chave neste processo.

A inclusão de um algoritmo de redução de dados pode diminuir o tempo de treinamento e também melhorar a capacidade de generalização (desempenho) da rede treinada. Na Figura 4.8, é mostrado um esquema genérico com as etapas que antecedem a utilização da RNA para classificação de sinais de vibração, em um processo de monitoramento.



Figura 4.8 – Etapas principais do processo de classificação (SANTOS, 2000)

Dentre os métodos de redução de dados, podemos citar a utilização da Transformada de Fourier ou Transformada Wavelet, e posterior utilização apenas das principais componentes de amplitude e frequência, a utilização de técnicas de tratamento estatístico e a posterior utilização dos parâmetros estatísticos, tais como média, valor médio quadrático (RMS – *Root Mean Square*), entre outros.

A Transformada de Fourier, é uma técnica bastante utilizada e a literatura discute várias aplicações da técnica. Li (2002) discute que esta técnica pode ser utilizada com sucesso, por exemplo, para o processamento de sinais captados por sensores de emissão acústica durante o processo de torneamento.

As equações (9) e (10) definem o par de Transformadas de Fourier (NEWLAND, 1989)

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega) e^{i\omega t} dt \quad (9)$$

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) e^{-i\omega t} dt \quad (10)$$

A equação (9) implica que o sinal $f(t)$ pode ser decomposto numa família de sinais harmônicos $e^{i\omega t}$ em que os coeficientes $F(\omega)$ representam a amplitude dos harmônicos em $f(t)$. $F(\omega)$ é independente do tempo, e representa a composição em frequência de um processo determinístico.

A Transformada Wavelet (TW) em complementação a Transformada de Fourier, é dita como uma transformada que não utiliza uma escala fixa na análise. A escala é definida pela largura da função de modulação, sendo utilizada portanto, uma função que não tenha escala fixa e que seja localizada no tempo.

A Transformada Wavelet de um sinal $x(t)$ é expressa como:

$$Wx(a,b) = \int_{-\infty}^{+\infty} x(t)\psi_{a,b}(t)dt \quad (11)$$

que, aproximando a integral por um somatório, torna-se

$$Wx(a,b) = \sum_{t=0}^{N-1} x(t)\psi_{a,b}(t) \quad (12)$$

para um sinal discreto com N pontos. A função $\psi_{a,b}(t)$, chamada “wavelet”, é derivada de uma função $\psi(t)$ através da seguinte transformação:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (13)$$

Na TW, o parâmetro b representa posição (ou “translação” da wavelet), e o parâmetro a (chamado parâmetro de “escala”) está associado à largura da janela.

Há uma ampla gama de possíveis escolhas para a função $\psi(t)$, denominada “*wavelet mãe*”. Algumas alternativas de famílias de wavelets conhecidas estão apresentadas na Figura 4.9.

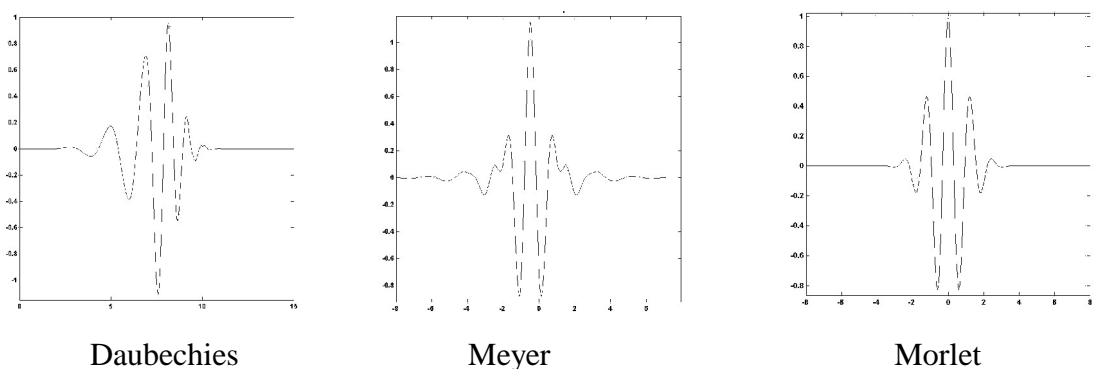


Figura 4.9 - Exemplos de Wavelets (SANTOS, 2000)

A modulação da função W pelo fator $\frac{1}{\sqrt{a}}$, faz com que sua amplitude aumente quando a escala a diminui e vice-versa. Em termos de frequência, para a pequena $W_{(a,b)}$ possui altas frequências e à medida que a aumenta, a frequência detectada diminui, Figura 4.10.




Figura 4.10 – Relação entre frequência e escala (SANTOS, 2000)

Neste capítulo foram abordados assuntos relativos a análise e o processamento dos sinais, a utilização de técnicas de redução de dados, algoritmos de treinamento, configuração e organização da rede neural artificial, os quais foram utilizados durante a realização dos testes experimentais, que será o próximo objeto de estudo.

CAPÍTULO 5

5. MATERIAIS, EQUIPAMENTOS E PROCEDIMENTOS EXPERIMENTAIS

5.1. INTRODUÇÃO

Este capítulo tem como objetivo descrever a implementação da metodologia proposta e a realização dos testes experimentais de monitoramento da vida da ferramenta, em um processo de torneamento a partir da aquisição dos dados de vibrações em situações reais. Foram utilizados os laboratórios e oficinas, bem como materiais e equipamentos disponíveis no Departamento de Engenharia Mecânica da Faculdade de Engenharia de Ilha Solteira na realização dos testes experimentais.

A máquina-ferramenta utilizada nos testes foi um torno mecânico convencional, de 3 kW de potência, sendo que foi avaliado o desgaste de dois tipos de ferramentas de corte. Os sinais de vibração foram medidos com acelerômetro posicionado no porta-ferramentas, utilizando um sistema de aquisição multicanais e os dados medidos foram armazenados em disco, para que fossem analisados posteriormente.

5.2. EQUIPAMENTOS UTILIZADOS E MONTAGEM DO SISTEMA DE MEDIÇÃO

Para a realização das medições foram utilizados os seguintes materiais e equipamentos:

MATERIAIS:

- □ aço ABNT 1045;
- □ porta-ferramenta para insertos de metal duro, cabo 20 x 20 mm x 125 mm, corte esquerda, para pastilha triangular com furo para fixação por parafuso, aresta de 16 mm (ISO STJBL 2020K16);
- □ inserto de metal duro com cobertura de nitreto de titânio, triangular, aresta de 16 mm, 3 mm de espessura e raio de ponta de 0,8 mm (TCMT16T308);
- □ inserto de metal duro sem cobertura, triangular, aresta de 16 mm, 3 mm de espessura e raio de ponta de 0,8 mm (TCMT16T308KM);

EQUIPAMENTOS:

- □ torno convencional marca NARDINI, 3kW de potência;
- □ acelerômetro, MMF, modelo KS50, sensibilidade: 2,36 mV/ms², faixa de temperatura de operação: 150 ° C;
- □ condicionador e amplificador de sinais, Brüel & Kjaer, modelo NEXUS;
- □ sistema de aquisição de dados Daq Book/112, placa DBK17 com 4 canais, taxa máxima de aquisição de 40 kHz;
- □ computador Notebook Toshiba, Pentium 166 MHz;
- □ software para aquisição de dados, DasyLab 4.0;
- □ Rugosímetro portátil, digital, marca MITUTOYO, modelo SJ-201P;
- □ Calibrador de acelerômetro, PCB, modelo 394B06;
- □ Estéreo-Microscópio, KALZEISS-JENA, aumento de 6,3 a 40 vezes.

O esquema de montagem do sistema de monitoramento é mostrado na Figura 5.1.



Figura 5.1 – Esquema de montagem do sistema de monitoramento.

Os sinais de vibração foram medidos com um sistema de aquisição Daq Book/112, placa DBK17 com 4 canais. O sensor utilizado foi um acelerômetro piezoelétrico apresentando características técnicas como tamanho, faixa de frequência e sensibilidade adequadas aos propósitos dos testes.

O acelerômetro foi acoplado no porta-ferramentas, sendo posicionado na direção do avanço conforme mostrado na Figura 5.2, para que a captura do sinal fosse a mais eficiente possível. O sinal de vibração de interesse é causado pelo atrito entre a ferramenta-peça e cavaco-ferramenta e espera-se que esta seja a posição mais adequada, neste sentido, testes preliminares foram realizados.



Figura 5.2 – Acelerômetro acoplado no porta-ferramenta.

A Figura 5.3 mostra o posicionamento do acelerômetro e porta-ferramentas no torno durante a usinagem.




Figura 5.3 – Posicionamento do acelerômetro e do porta-ferramentas no torno.

O desgaste da ferramenta foi monitorado para um conjunto de corpos de prova. Os corpos de prova utilizados são de aço ABNT 1045, e apresentam dimensões mostradas na Figura 5.4.



Figura 5.4 – Desenho dos corpos de prova utilizados.

5.3. PROGRAMA DE AQUISIÇÃO E AMOSTRAGEM

O sistema de aquisição Daq Book/112 foi utilizado para a conversão do sinal analógico para sinal digital, controlado pelo software *DasyLab 4.0*, que permite adquirir e armazenar os dados em disco para que possam ser processados e analisados posteriormente.

O sinal foi amostrado em 20 kHz, tomando como base informações da literatura que aponta que maiores componentes de frequência dos sinais de vibração se encontra na faixa de 4 a 8 kHz nas condições analisadas. O condicionador de sinais foi configurado com um filtro passa baixa, com frequência de corte em 10 kHz.

Os sinais de vibração foram adquiridos com um acelerômetro piezoelétrico, posicionado no porta-ferramenta. Os sinais foram adquiridos em doze posições diferentes ao longo de cada peça, conforme mostrado na Figura 5.5, utilizando a frequência de amostragem de 20 kHz.




Figura 5.5 – Posições para amostragem dos sinais nos corpos de prova

O software de aquisição foi configurado para adquirir os sinais em 3 séries de 4096 pontos (*Running Series*) em cada uma das doze posições diferentes ao longo de cada peça, sendo iniciado o processo de aquisição no instante em que a ferramenta tocava a peça. Foram utilizados os seguintes módulos do software *DasyLab 4.0*, conforme discutido na Figura 5.6:

- □ Conversor Analógico/Digital
- □ Filtro passa alta, permitindo frequências acima de 70Hz
- □ Ajuste de escala
- □ Transformada Rápida de Fourier (FFT)
- □ Visualização gráfica da FFT
- □ Visualização gráfica do sinal adquirido
- □ Armazenamento em disco dos sinais adquiridos

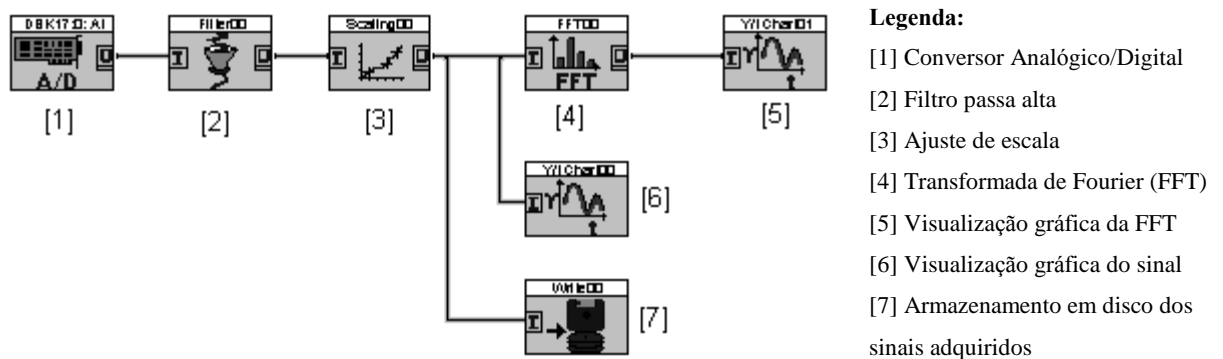


Figura 5.6 – Configuração do software *DasyLab* para aquisição de dados.

5.4. ENSAIOS PRELIMINARES

Os ensaios preliminares tiveram como objetivo realizar os ajustes e a familiarização com os equipamentos, bem como testar as condições de usinagem a serem empregadas no experimento, tais como rotação, profundidade de corte e avanço.

No trabalho de Bonifácio (1993), foi realizado um levantamento sobre as faixas de frequências para o estudo do monitoramento via vibração, sendo verificado que a faixa de frequências adequada vai de 0 a 20000 Hz, embora uma faixa de até 8 kHz seja adotada pela maioria dos pesquisadores.

Uma identificação prévia das características do sinal, foi realizada visando uma melhor redefinição das condições de aquisição. Estes testes foram realizados buscando levantar as seguintes condições:

- □ Verificação de faixas de frequência em que espectro do sinal apresenta as principais componentes;
- □ Verificação da variação da amplitude do sinal, para as condições de usinagem utilizadas, com o objetivo de identificar a possibilidade de eventual saturação do sensor;
- □ Identificação da contaminação do sinal pelo ruído de fundo (valores do sinal com a máquina operando em vazio).

Este levantamento foi realizado para as situações de torneamento mostradas na tabela 5.1, utilizando-se uma ferramenta que já havia sido utilizada anteriormente, porém em boas condições de uso. Para todas as condições utilizou-se uma profundidade de usinagem (a_p) de 1mm.

Tabela 5.1 – Parâmetros para o torneamento.

Velocidade de corte (V_c) (m/min)	Avanço (f) (mm/volta)	Rotação (n) (rpm)	Diâmetro da peça (d) (mm)
100	0,19	630	50,00
100	0,19	800	39,38
100	0,19	1000	31,50
100	0,19	1250	25,20

Os ensaios foram realizados selecionando, inicialmente, a rotação de 630 rpm e corpo de prova com 50 mm de diâmetro. O software de aquisição foi ajustado com os parâmetros e intervalo de aquisição adequados para a realização da amostragem, nas doze posições ao longo da peça, permitindo a realização da usinagem nas condições adotadas, assim como a verificação dos resultados obtidos e as respectivas adequações e ajustes necessários. Repetiu-se o processo para as demais condições de usinagem, isto é, rotações de 800, 1000 e 1250 rpm, com o objetivo de realizar um levantamento de todas as informações relevantes do processo.

Testes adicionais também foram realizados mudando a posição do acelerômetro. Neste caso, posicionou-se o acelerômetro nas proximidades dos mancais do torno mecânico, buscando identificar eventuais frequências relacionadas com o movimento do conjunto de engrenagens, durante o processo de usinagem. Os sinais foram adquiridos com o torno ligado, em vazio (sem a realização de usinagem), utilizando os mesmos parâmetros de usinagem apresentados anteriormente. A Figura 5.7 mostra o espectro de frequência obtido, como pode ser observado o sinal apresenta componentes de frequência bem distintas, em torno de 900 Hz, 2100 Hz e 2350 Hz e ampla faixa de frequência entre 2700 e 3200 Hz.




Figura 5.7 – Espectro do sinal medido nas proximidades dos mancais do torno.

Um outro teste também foi realizado com o acelerômetro posicionado no porta-ferramentas, o torno foi ligado e realizou-se um passe em vazio, ou seja, sem efetuar a usinagem do material, objetivando identificar as freqüências no ponto em que se deseja captar os sinais. A Figura 5.8 mostra que as mesmas faixas de freqüências apresentadas anteriormente são observadas, porém com menor amplitude.




Figura 5.8 – Espectro do sinal medido no porta-ferramentas.

Uma vez realizados os testes preliminares, passou-se para o ensaio de desgaste da ferramenta. Os testes preliminares serviram para se ter uma maior segurança quanto aos dados e parâmetros obtidos nos ensaios, bem como, à própria confiança em relação ao manuseio dos equipamentos e definição dos parâmetros de aquisição, tempo de amostragem, número de pontos, etc., tendo em vista que diferentes condições foram analisadas.

5.5. ENSAIOS DE DESGASTE

Os ensaios de desgaste foram realizados utilizando corpos de provas de aço ABNT 1045, sendo que a evolução do desgaste da ferramenta de corte foi avaliada através de medidas de rugosidade da peça a cada passe. O acabamento superficial da peça era monitorado (medida da rugosidade). Os níveis dos sinais de vibração também foram

monitorados visando estabelecer correlações entre o desgaste da ferramenta e o aumento dos níveis dos sinais de vibração, dados estes que seriam utilizados no treinamento da RNA. Foram utilizados dois tipos de ferramentas de corte: pastilhas de metal duro com cobertura de nitreto de titânio e pastilhas de metal duro sem cobertura.

Nos primeiros dois ensaios, verificou-se a evolução do desgaste da ferramenta, utilizando o aço ABNT 1045, corpos de prova de 50 mm de diâmetro por 220 mm de comprimento, usinados com fixação entre placa e a ponta, sem fluido de corte e nas mesmas condições de usinagem mostradas na tabela 5.1.

Neste caso foram utilizadas pastilhas triangular de metal duro com cobertura de nitreto de titânio, aresta de 16 mm, 3 mm de espessura e raio de ponta de 0,8 mm (TCMT16T308). A velocidade de corte manteve-se constante, $V_c = 100$ m/min. Para manter a velocidade de corte constante, trabalhou-se com quatro diferentes rotações, 630, 800, 1000 e 1250 rpm, e conseqüentemente, diferentes valores de diâmetros dos corpos de prova. Os diâmetros utilizados foram 50, 39,38, 31,50 e 25,20 mm correspondendo, respectivamente, as rotações de 630, 800, 1000 e 1250 rpm.

Para cada rotação utilizada, os corpos de prova foram usinados e preparados previamente com uma outra ferramenta de corte do mesmo tipo, que não estava sendo monitorado o desgaste. Isso foi feito para se conseguir uma velocidade de corte constante, $V_c=100$ m/min, conforme especificado.

Para o acompanhamento do desgaste da ferramenta, foram feitas medidas da rugosidade da peça durante a usinagem. A rugosidade média R_a (μm) foi medida a cada dois passes, em três posições ao longo de cada peça (início, meio e fim a partir do contra-ponta), utilizando um rugosímetro portátil, digital, marca MITUTOYO, modelo SJ-201P, conforme mostrado na Figura 5.9.


Após a medição da rugosidade, a ferramenta de corte era levada ao estereomicroscópio para verificar o desgaste de flanco ($VB_{\text{máx}}$), o qual foi usado como critério de fim de vida da ferramenta, juntamente com os valores da rugosidade.

Foram especificadas como critérios de fim de vida da ferramenta as seguintes situações:

- a) o valor de $VB_{\text{máx}}$ maior ou igual a $0,20 \mu\text{m}$;
- b) valor da rugosidade pelo menos duas vezes maior que a rugosidade do primeiro corpo de prova usinado.



a) Rugosímetro posicionado junto ao corpo de prova



b) Detalhe da ponta do rugosímetro

Figura 5.9 – Medição da rugosidade utilizando um rugosímetro digital.

A ferramenta de corte era considerada como imprópria para continuar sendo utilizada, ou com risco de quebra, quando um dos dois critérios acima fosse atingido.

O primeiro ensaio foi composto de uma bateria de testes realizados conforme discutido a seguir:

1. Com uma aresta nova iniciava-se o ensaio nas condições pré-determinadas;
2. O corpo de prova era usinado em dois passes de 1mm cada, sendo gerados os arquivos de sinais de vibração, contendo os dados relativos às doze posições amostradas em cada passe;
3. Após os dois passes, o corpo de prova era levado ao rugosímetro e media-se a rugosidade em três posições (início, meio e fim) e, em seguida, o desgaste de flanco era medido no estéreo-microscópio;
4. Com um novo corpo de prova, repetiam-se os procedimentos 2 e 3;
5. O ensaio era finalizado ao atingir uma rugosidade no mínimo duas vezes maior que a do primeiro corpo de prova usinado ou $VB_{máx} = 0,20 \mu\text{m}$ (critério de fim de vida);
6. Após a usinagem de todos os corpos de prova, numa determinada rotação, os corpos eram desbastados com outra ferramenta de corte, até chegar ao respectivo diâmetro em que utilizando a próxima rotação disponível, se conseguia a mesma velocidade de corte. O ensaio era reiniciado, com a ferramenta monitorada, a partir do passo 2.

No segundo ensaio, com pastilha de metal duro com cobertura de nitreto de titânio, os testes foram realizados em condições semelhantes de usinagem, mas para uma outra velocidade de corte constante, $V_c = 200$ m/min. Neste caso, foi utilizado apenas a rotação de 1250 rpm.

O monitoramento da rugosidade foi realizado a cada três passes, a partir da rugosidade média R_a (μm), medida em três pontos diferentes da seção transversal no meio da peça.

Após a medição da rugosidade, a ferramenta de corte era levada ao estereomicroscópio para verificar o desgaste de flanco ($VB_{\text{máx}}$), o qual foi usado como critério de fim de vida da ferramenta, juntamente com os valores da rugosidade.

Adotou-se como critérios de fim de vida da ferramenta as seguintes situações:

- a) o valor de $VB_{\text{máx}}$ maior ou igual a $0,20 \mu\text{m}$;
- b) valor da rugosidade pelo menos duas vezes maior que a rugosidade do primeiro corpo de prova usinado.

A ferramenta de corte era considerada como imprópria quando um dos dois critérios acima fosse alcançado.

O ensaio desenvolveu-se do seguinte modo:

1. Com uma aresta nova iniciava-se o ensaio nas condições determinadas;
2. O corpo de prova era usinado em dois passes de 1mm cada, e os sinais de vibração foram medidos em doze posições distintas ao longo da peça, amostradas em cada passe;
3. Após os dois passes, o corpo de prova era levado ao rugosímetro e media-se a rugosidade em três posições (início, meio e fim) e, em seguida, o desgaste de flanco era medido no estereomicroscópio;
4. Com um novo corpo de prova, repetiam-se os procedimentos 2 e 3;
5. O ensaio era finalizado ao atingir uma rugosidade no mínimo duas vezes maior que a do primeiro corpo de prova usinado ou $VB_{\text{máx}} = 0,20 \mu\text{m}$ (critério de fim de vida);

No terceiro teste utilizou-se um outro tipo de ferramenta de corte, pastilha triangular de metal duro sem cobertura, aresta de 16 mm, 3 mm de espessura e raio de ponta de 0,8 mm (TCMT16T308KM). Os ensaios foram realizados em diferentes condições de usinagem, mantendo a velocidade de corte $V_c = 110$ m/min para a rotação de 1000 rpm e a velocidade $V_c = 140$ m/min para a rotação de 1250 rpm.

A rugosidade média R_a (μm) da peça neste caso, foi obtida em três posições ao longo de cada peça (início, meio e fim a partir do contra-ponta) em cada passe.

Após a medição da rugosidade, a ferramenta de corte era levada ao estereomicroscópio para verificar o desgaste de flanco ($VB_{\text{máx}}$), o qual foi usado como critério de fim de vida da ferramenta, juntamente com os valores da rugosidade.

Adotou-se como critérios de fim de vida da ferramenta as seguintes situações:

- a) o valor de $VB_{\text{máx}}$ maior ou igual a $0,20 \mu\text{m}$;
- b) valor da rugosidade pelo menos duas vezes maior que a rugosidade do primeiro corpo de prova usinado.

A ferramenta de corte era considerada como imprópria ou com risco de quebra quando um dos dois critérios acima fosse alcançado.

O ensaio desenvolveu-se do seguinte modo:

1. Com uma aresta nova iniciava-se o ensaio nas condições determinadas;
2. O corpo de prova era usinado em um passe de 1mm, sendo gerados doze arquivos de sinais, contendo os dados relativos às doze posições amostradas;
3. Após cada passe, o corpo de prova era levado ao rugosímetro e media-se a rugosidade em três posições (início, meio e fim) e, em seguida, o desgaste de flanco era medido no estereomicroscópio;
4. Com um novo corpo de prova, repetiam-se os procedimentos 2 e 3;
5. O ensaio era finalizado ao atingir uma rugosidade no mínimo duas vezes maior que a do primeiro corpo de prova usinado ou $VB_{\text{máx}} = 0,20 \mu\text{m}$ (critério de fim de vida);

O processo de medição dos sinais de vibração ocorreu em paralelo com as medidas de rugosidade, em todos os testes realizados. Os sinais foram adquiridos por um acelerômetro piezoelétrico, posicionado no porta-ferramenta, sendo adquiridos em doze posições diferentes ao longo de cada peça, utilizando uma frequência de amostragem de 20 kHz.

Os sinais foram adquiridos em doze posições ao longo do corpo de prova, sendo que em cada uma das posições foram coletadas três séries de 4096 pontos cada, os quais foram armazenados em disco para posterior análise. Após o término do processo de aquisição dos dados, calculou-se a média dos sinais para cada posição de medida, utilizando os módulos de cálculo do próprio *DasyLab 4.0*.

Os sinais de vibração medidos, foram utilizados como entrada no processo de treinamento e validação da rede neural para a identificação do estado da ferramenta de corte.

Para a utilização destes dados em conjunto com redes neurais artificiais, é necessário que haja um pré-processamento, utilizando técnicas de redução de dados, cuja finalidade é gerar um conjunto de dados que contenha as principais informações do sinal.

Um dos métodos de redução de dados utilizados neste trabalho, foi o cálculo do valor RMS (*Root Mean Square*) dos sinais de vibração, ou seja, o valor médio quadrático, cujos valores foram utilizados como entrada para a rede neural.

Outro método utilizado foi a Transformada Wavelet Discreta. Neste caso, a redução de dados consistiu em decompor os sinais de vibração em várias componentes. Para cada componente decomposta da transformada wavelet, calculou-se os valores RMS, os quais também foram utilizados como entrada para a rede neural artificial.

Com a realização destes ensaios, obteve-se dados em condições semelhantes de usinagem. Os dados obtidos foram analisados e utilizados no processo de validação da metodologia proposta, visando verificar o comportamento e evolução do desgaste da ferramenta, bem como na identificação do momento adequado para substituição da ferramenta.

CAPÍTULO 6

6. IDENTIFICAÇÃO DO DESGASTE DA FERRAMENTA UTILIZANDO SINAIS DE VIBRAÇÃO

6.1. INTRODUÇÃO

Este capítulo descreve como os dados adquiridos nos ensaios experimentais foram utilizados para o monitoramento e avaliação do desgaste de ferramentas de corte no processo de torneamento. São abordados os aspectos envolvidos na análise e o processamento dos sinais, a utilização de técnicas de redução de dados, uma discussão a respeito da configuração e organização da rede neural artificial, bem como a apresentação dos resultados obtidos. Os sinais de vibração foram utilizados para a definição de um banco de dados referente às condições de desgaste da ferramenta de corte. O estado de desgaste da ferramenta foi separado em quatro estágios de desgaste (estágio inicial, estágio intermediário, estágio avançado e estágio crítico) e os dados referentes a cada estágio foram utilizados para o treinamento e validação da rede neural artificial, permitindo determinar as condições de desgaste da ferramenta.

6.2. INFLUÊNCIA DA RIGIDEZ DOS DISPOSITIVOS DE FIXAÇÃO E DA PEÇA NO ACABAMENTO SUPERFICIAL

A qualidade do acabamento superficial no processo de usinagem, conforme discutido anteriormente, é fortemente influenciada pelo estado da ferramenta e da velocidade de corte.

O objetivo deste ensaio é discutir a influência da rigidez dos dispositivos de fixação e da peça no acabamento superficial, utilizando para tal a medida da rugosidade da peça. Foram realizados vários ensaios, alterando-se a rotação do torno para as condições de: 630, 800, 1000 e 1250 rpm. Utilizou-se nos ensaios, ferramenta de metal duro sem cobertura e com cobertura de nitreto de titânio e o aço usinado foi o ABNT 1045.

A rugosidade foi medida em três posições ao longo do corpo de prova (início, meio e fim a partir do contra-ponta), buscando verificar a influência da posição da medida na

avaliação da rugosidade. Os resultados mostraram que a posição da medida tem influência nos valores medidos, sendo assim necessário a adoção de um ponto de referência a ser tomado como base para análise e comparação dos resultados. Isso permite uma maior padronização dos dados a serem utilizados na determinação da rugosidade da peça.

6.2.1. ENSAIOS UTILIZANDO FERRAMENTA COM COBERTURA

Nestes ensaios utilizou-se ferramenta com cobertura de nitreto de titânio e rotações 630, 800, 1000 e 1250 rpm. Como discutido anteriormente, a rugosidade da peça foi avaliada em três posições (início, meio e fim), em cada posição de medição os dados foram medidos em três pontos, definidos a zero, 120 e 240 graus na seção transversal do corpo de prova, e posteriormente calculado o valor médio. As Figuras 6.1 a 6.4 mostram os resultados dos valores médios da rugosidade entre os três pontos.

O gráfico da Figura 6.1 mostra os resultados obtidos para a menor rotação utilizada nos testes, ou seja, rotação de 630 rpm.




Figura 6.1 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 630 rpm.

O gráfico mostra que, para as posições do início e meio dos corpos de provas (CPs) usinados, a rugosidade média evoluiu com um comportamento semelhante, mostrando uma tendência de aumento até o comprimento de corte (Lc) 3597 m, e a partir desse ponto nota-se a ocorrência de variação nos valores medidos. Para os valores medidos na posição próxima ao

fim do corpo de prova, a evolução da rugosidade apresentou-se com menor variação e seguiu uma tendência de crescimento mais estável. Outro aspecto observado foi a influência da rigidez do sistema Máquina / Ferramenta / Dispositivos de Fixação / Peça (MFDP) no acabamento superficial da peça. Verifica-se que na posição próxima ao contra-ponta onde a rigidez é menor, a rugosidade foi maior. No meio da peça onde a rigidez tem um valor intermediário a rugosidade foi menor que no caso anterior, e na posição próxima à placa onde a rigidez é maior, a rugosidade foi menor. Acredita-se que isso ocorreu, devido ao fato de que houve uma combinação dos efeitos da rotação e da rigidez do sistema, que causou um nível de vibração que resultou nas rugosidades obtidas. Na posição final de cada corpo de prova, isto é, posição próxima do dispositivo de fixação da peça (placa), a vibração da peça foi menor em função da maior rigidez e a rugosidade medida teve uma variação com uma tendência mais uniforme.

Comparando-se os resultados entre as medidas de rugosidade nas três posições ao longo do percurso de corte, após a usinagem de todos os corpos de prova, verificou-se que no final do ensaio ($L_c = 6218$ m) o valor da rugosidade média é aproximadamente duas vezes maior do que o valor medido no início do ensaio ($L_c = 334$ m). Esse valor, isto é, aumento de duas vezes a rugosidade inicial, foi tomado como critério de fim de vida da ferramenta.

A Figura 6.2 mostra a evolução da rugosidade média medida nas três posições ao longo do corpo de prova (início, meio e fim), utilizando a rotação de 800 rpm.

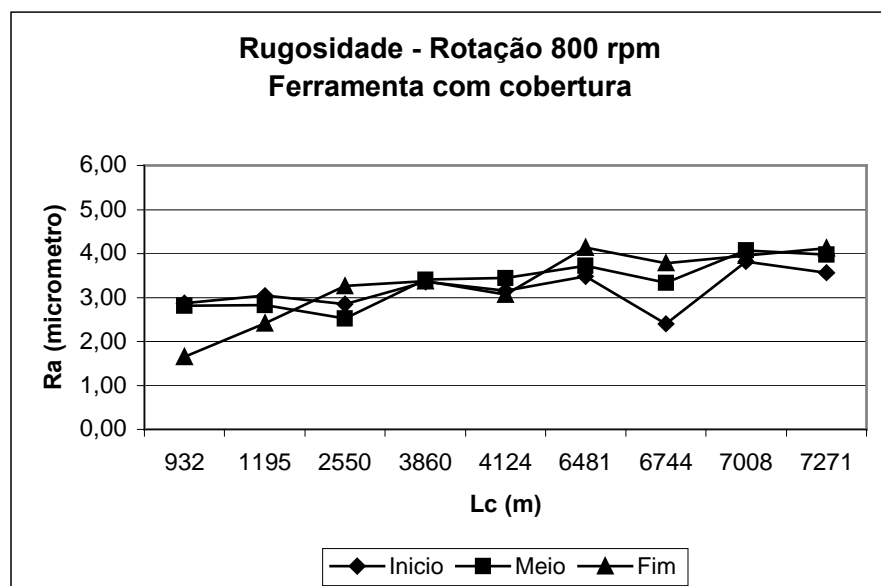


Figura 6.2 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 800 rpm.

Nota-se que a rugosidade medida na posição de início da peça teve um aumento até a posição relativa a $L_c = 6481$ m, tendo uma ligeira queda e em seguida um aumento. Para os valores medidos no meio da peça, o comportamento da evolução da rugosidade foi semelhante aos da posição no início da peça, porém não ocorreu uma redução tão acentuada na posição do $L_c = 6744$ m, conforme observado na posição de início da peça, e os valores da rugosidade na posição relativa ao $L_c = 7271$ m, correspondentes ao final do ensaio, não são tão próximos.

Verificou-se que na posição medida no fim da peça, a rugosidade teve uma tendência de aumento mais estável, porém nota-se que houve também uma região de ligeira queda ($L_c = 6744$ m), mas com aumento nas posições subseqüentes, resultando em valores praticamente idênticos aos medidos no meio da peça para a posição $L_c = 7271$ m.

Neste caso, os valores da rugosidade não foram muito diferentes nas três posições. Isto pode ter acontecido devido à combinação dos efeitos da rotação e da rigidez do sistema que causou níveis de vibração semelhantes nas três posições.

Nas Figuras 6.3 e 6.4 são mostradas as medidas de rugosidade, nas três posições do corpo de prova, utilizando as rotações 1000 e 1250 rpm, respectivamente.




Figura 6.3 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 1000 rpm.




Figura 6.4 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta com cobertura – rotação 1250 rpm.

Analisando os gráficos, observa-se que os valores medidos na rotação 1000 rpm mostraram uma tendência de crescimento, sendo que os valores da rugosidade nas posições do meio e fim do corpo de prova permaneceram mais próximos e houve uma maior variação nos valores medidos na posição de início do corpo de prova.

Na rotação 1250 rpm nota-se que a rugosidade teve pouca variação entre as três posições medidas (início, meio e fim do corpo de prova), mantendo uma tendência de crescimento melhor definida e com valores bem próximos entre as três posições de medição de cada corpo de prova.

Nestes dois casos, a explicação é também a de que a combinação dos efeitos da rotação e da rigidez do sistema causou níveis de vibração praticamente iguais nas três posições.

Comparando-se os gráficos mostrados nas Figuras 6.1 a 6.4, observa-se que a evolução da rugosidade teve um comportamento de aumento não muito bem definido para a rotação de 630, ocorrendo variações entre as amplitudes coletadas em cada uma das três posições de medição, sendo que, com o aumento da rotação para 800 rpm a evolução da rugosidade comportou-se de modo mais estável, tendo menores variações nas amplitudes entre as três posições analisadas. Para a rotação 1250 rpm, a rugosidade teve menor variação entre as três posições medidas (início, meio e fim), mantendo uma tendência de crescimento. Os valores medidos utilizando a rotação 1000 rpm, também mostraram essa tendência de

crescimento, entretanto, os valores da rugosidade na posição iniciais tiveram uma maior oscilação, enquanto que, os valores nas posições do meio e fim do corpo de prova permaneceram mais próximos. Pode-se verificar claramente a influência da rotação no acabamento superficial, sendo que a rotação ideal depende da rigidez do sistema MFDP.

Conclui-se que, para as condições de usinagem utilizadas nos testes experimentais, as rotações de 1000 e 1250 rpm apresentaram uma variação mais uniforme no aumento da rugosidade superficial, com o tempo de vida da ferramenta (desgaste). Estes valores de rotações foram utilizados nos demais ensaios realizados. As variações observadas na evolução do acabamento superficial, utilizando as rotações 630 e 800 rpm, indicam maior influência da rigidez do sistema MFDP no aumento da rugosidade superficial, sendo contribuída, possivelmente, pela realização da usinagem em condições fora da faixa recomendada para os parâmetros adotados.

6.2.2. ENSAIOS UTILIZANDO FERRAMENTA SEM COBERTURA

A ferramenta utilizada nestes ensaios foi de metal duro sem cobertura, a rotação do torno foi definida para as condições de 1000 e 1250 rpm, e não foi realizado o desbaste nos corpos de prova para atingir o diâmetro correspondente à próxima rotação disponível (ver item 5.5), mantendo o mesmo diâmetro para as rotações utilizadas. A rugosidade da peça também foi avaliada em três posições (início, meio e fim a partir do contra-ponta), sendo que em cada posição de medição os dados foram medidos em três pontos, definidos a zero, 120 e 240 graus na seção transversal do corpo de prova, e posteriormente calculados os valores médios.

Os gráficos das Figuras 6.5 e 6.6 mostram os resultados dos valores médios da rugosidade entre os três pontos, obtidos para a rotação de 1000 e 1250 rpm, respectivamente.




Figura 6.5 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta sem cobertura – rotação 1000 rpm.




Figura 6.6 – Medidas de rugosidade no início, meio e fim da peça utilizando ferramenta sem cobertura – rotação 1250 rpm.

Analisando os gráficos, verifica-se que os valores medidos na rotação 1000 rpm tiveram uma tendência de crescimento e pouca variação entre as três posições de medição (início, meio e fim de cada corpo de prova) ao longo do ensaio. Observa-se utilizando a

rotação 1250 rpm que a rugosidade teve pouca variação entre as três posições de medição, mantendo também uma tendência de crescimento.

Comparando-se os gráficos apresentados nas Figuras 6.5 e 6.6, nota-se que com o aumento da rotação, e conseqüentemente aumento da velocidade de corte, pelo fato de não ter sido diminuído o diâmetro das peças como nos outros ensaios, o tempo de vida da ferramenta diminuiu consideravelmente. A evolução da rugosidade teve uma tendência de crescimento uniforme, independentemente da posição de medição no corpo de prova e da rotação utilizada.

O gráfico apresentado na figura 6.7 ilustra a evolução da rugosidade para as rotações 1000 e 1250 rpm. Cada ponto no gráfico representa o valor médio entre as três posições de medição da rugosidade ao longo dos corpos de prova (início, meio e fim a partir do contra-ponta).

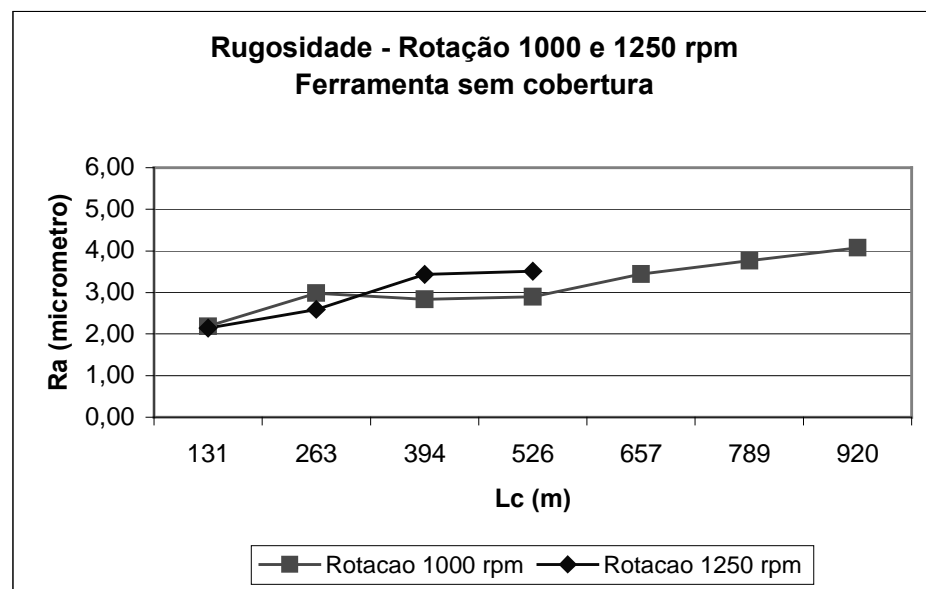


Figura 6.7 – Medidas de rugosidade utilizando ferramenta sem cobertura – rotações 1000 e 1250 rpm.

Verifica-se no gráfico que utilizando a rotação de 1000 rpm o comprimento de corte obtido foi de aproximadamente 920 m, até o momento adotado como critério de fim de vida da ferramenta. Nos resultados obtidos utilizando a rotação de 1250 rpm, verifica-se que o processo de usinagem foi finalizado ao atingir $L_c = 526$ m, após a verificação da deterioração da aresta de corte da ferramenta. Isso foi observado antes de atingir o critério adotado como fim de vida da ferramenta, ou seja, o valor da rugosidade duas vezes maior em relação ao primeiro valor. O comprimento de corte verificado foi de 526 m, resultando em uma diferença

em torno de 75% a menos em relação ao comprimento de corte obtido utilizando a rotação de 1000 rpm.

Conclui-se que com a utilização da ferramenta sem cobertura e as rotações de 1000 e 1250 rpm não houve variações na rugosidade, sendo medidos valores que indicaram uma tendência uniforme de crescimento, mostrando que, neste caso, houve pouca influência da rigidez do sistema MFDP.

6.3. CORRELAÇÃO ENTRE A RUGOSIDADE DA PEÇA E OS SINAIS DE VIBRAÇÃO

Os resultados dos testes acima, isto é, a constatação de que a evolução da rugosidade da peça teve uma variação mais uniforme nas rotações de 1000 e 1250 rpm, foram utilizados para a definição dos testes adicionais usados para verificar a variação dos valores RMS dos sinais de vibração. O objetivo foi estabelecer a correlação entre a evolução da rugosidade e dos valores RMS dos sinais de vibração. Neste caso, utilizou-se apenas a rotação de 1250 rpm.

A ferramenta utilizada nos testes foi uma ferramenta de metal duro com cobertura de nitreto de titânio e a peça de aço ABNT 1045. A rugosidade média foi calculada apenas para a posição de medição no meio de cada um dos dezoito corpos de prova utilizados. Essa média foi obtida tomando os valores medidos em pontos definidos a zero, 120 e 240 graus na seção transversal do corpo de prova.

O gráfico mostrado na Figura 6.8 ilustra a evolução da rugosidade utilizando a rotação de 1250 rpm.




Figura 6.8 – Variação da rugosidade – rotação 1250 rpm.

Nota-se no gráfico da rugosidade uma tendência de crescimento no início do ensaio até $L_c = 837$ m, seguida de uma ligeira queda até $L_c = 1171$ m e, posteriormente, verifica-se oscilações nos valores da rugosidade, porém com tendência de crescimento com o aumento do comprimento de corte. Isto ocorreu porque no início até $L_c = 837$ m só ocorreu desgaste de flanco e a rugosidade aumentou quase que linearmente. Depois, o efeito do surgimento do desgaste de cratera, observado através das medidas de desgaste de flanco realizadas no microscópio, começou a interferir no valor da rugosidade, ou seja, com o aumento do valor do desgaste de cratera, ocorreram alterações na geometria da ferramenta, fazendo com que o acabamento superficial da peça oscilasse de acordo com a acomodação da aresta de corte.

Os valores RMS dos sinais de vibração, obtidos utilizando a rotação 1250 rpm, são mostrados na Figura 6.9. Cada ponto na figura representa a média dos valores RMS dos sinais de vibração, calculada com os valores obtidos nas doze posições diferentes amostradas ao longo de cada corpo de prova.




Figura 6.9 – Variação dos valores RMS dos sinais de vibração – rotação 1250 rpm.

Observa-se através do gráfico da Figura 6.9, que inicialmente os valores RMS dos sinais de vibração têm ligeiro aumento, vindo a estabilizar-se e manter-se com uma pequena tendência de crescimento. No entanto, o gráfico não mostra o aumento abrupto, resultado da quebra ou remoção da camada de cobertura da ferramenta, pois o critério de fim de vida da ferramenta adotado, duas vezes o valor da rugosidade inicial ou $VB_{m\acute{a}x} = 0,20 \mu\text{m}$, foi atingido antes da quebra da ferramenta.

Comparando os gráficos mostrados nas Figuras 6.8 e 6.9, nota-se que o valor RMS não acompanhou exatamente os picos de aumento da rugosidade. Esse comportamento pode ser explicado pela influência da rigidez do sistema MFDP, bem como do surgimento do desgaste de cratera, fazendo com que ocorresse alteração no escoamento do cavaco, sendo, conseqüentemente, modificados os níveis de vibração no porta-ferramenta.

Os resultados dos testes experimentais apresentados foram analisados, procurando-se estabelecer critérios que pudessem ser usados para padronizar a execução dos ensaios relativos à medição da rugosidade para definição da vida da ferramenta, bem como estabelecer uma correlação com os valores RMS do sinal de vibração. Identificou-se as posições de medição em que as medidas da rugosidade no corpo de prova apresentaram menor oscilação, além da influência da rotação no acabamento da peça. De acordo com os resultados obtidos, foi observado que as rotações de 1000 e 1250 rpm apresentaram uma variação mais uniforme do aumento da rugosidade, com o tempo de vida da ferramenta. A evolução do desgaste da ferramenta, através dos valores RMS dos sinais de vibração, também foi avaliada. Esses valores serão utilizados como entrada para o treinamento e validação das

redes neurais artificiais, objetivando a identificação do estágio de desgaste da ferramenta, com o intuito de determinar o momento mais adequado para a sua substituição.

6.4. TREINAMENTO DA REDE NEURAL ARTIFICIAL

Os dados obtidos nos testes experimentais de medição dos níveis de vibração serão utilizados para a avaliação da capacidade das redes neurais artificiais determinar as condições de vida de ferramentas de corte, em um processo de torneamento. Os dados foram previamente separados em quatro níveis ou estágios de desgaste, organizados e descritos a seguir:

a) estágio inicial:

Nessa etapa há um ligeiro aumento nos valores dos sinais de vibração com relação ao tempo de uso da ferramenta, a qual equivale a um aumento do desgaste de flanco ($VB_{máx}$) em torno de 50% do valor medido inicialmente no primeiro corpo de prova ou valores da rugosidade média (Ra) em torno de $2,0 \mu m$.

b) estágio intermediário:

Nesta etapa há uma tendência dos valores do sinal de vibração se manterem aproximadamente constantes com o tempo de vida da ferramenta, suas variações foram lentas, a menos de alguns pontos isolados. O tempo de vida da ferramenta neste estágio é maior, comparado com os demais, e é equivalente ao aumento do $VB_{máx}$ em aproximadamente 100% em relação ao estágio de desgaste inicial ou $Ra = 3,0 \mu m$.

c) estágio avançado:

Esta fase é caracterizada por um aumento dos sinais de vibração, após um período em que os mesmos praticamente não apresentam variações com o tempo. É equivalente ao aumento em torno de 30% do desgaste de flanco em relação ao estágio intermediário ou o valor da rugosidade média em torno de $3,7 \mu m$. Esta fase requer uma atenção especial no acompanhamento do processo de desgaste, pois ao fim deste estágio, a ferramenta pode causar danos à peça, ou seja, ao final deste estágio o processo de usinagem deve ser interrompido e a ferramenta substituída.

d) estágio crítico:

É a fase mais crítica do processo, sendo definida pelo crescimento abrupto do sinal de vibração e é equivalente a um valor da rugosidade duas vezes maior de que o valor inicial ($Ra = 4,0 \mu m$) ou $VB_{máx}$ maior ou igual a $0,20 \mu m$. Esse estágio,

conforme discutido anteriormente, precede a troca de ferramenta, no processo de usinagem convencional, ou seja, o operador deve providenciar imediatamente a substituição da ferramenta.

É importante salientar que neste caso, o crescimento abrupto do sinal de vibração não foi detectado nos testes realizados, pelo fato de que os critérios adotados como fim de vida da ferramenta, foram atingidos antes de iniciar tal crescimento do sinal de vibração. No trabalho de Hara (1995), esse momento é detectado (aumento abrupto dos valores RMS do sinal de vibração) a partir da remoção da cobertura da ferramenta, que passa a realizar o corte sem seu substrato, o que aumenta substancialmente a taxa de desgaste.

Os estágios de desgaste da ferramenta foram definidos com base nos valores dos dados obtidos na medição da rugosidade (R_a) da peça, e a partir da evolução destes dados definiu-se os níveis de desgaste. Posteriormente, os valores RMS dos sinais de vibração foram associados com esses dados, permitindo assim a definição dos níveis de evolução do desgaste da ferramenta em termos dos valores de vibração.

Definidos os vários estágios de desgastes, os sinais foram utilizados no treinamento de redes neurais que poderiam monitorar a ferramenta de corte identificando os estágios de desgaste. A rede neural artificial treinada, se funcionando em tempo real, forneceria de imediato a indicação do estado da ferramenta, constituindo-se em um importante auxílio para o monitoramento do desgaste até o fim da vida da mesma. A classificação e identificação dos estágios de desgaste, neste caso, permite estabelecer o momento mais adequado para a substituição da ferramenta com base nas medidas de vibração. É importante ressaltar que, neste caso, a ferramenta deve ser retirada de uso quando os sinais de vibração estiverem na iminência do desgaste crítico.

Os sinais de vibração medidos nos testes experimentais, foram inicialmente processados e posteriormente reduzidos em um número limitado de dados, através de um processo de compressão, conforme discutido no item 4.10. No primeiro caso, foram utilizados os valores RMS dos sinais medidos e em uma segunda etapa, utilizou-se a decomposição wavelet.

6.4.1. VALORES RMS DOS SINAIS DE VIBRAÇÃO – FERRAMENTA COM COBERTURA

Neste primeiro caso, os sinais de vibração foram adquiridos em doze posições ao longo do corpo de prova e os valores RMS (*Root Mean Square*) foram calculados para cada posição, os quais serão utilizados como dados de entrada da rede neural. Os dados foram separados em dois conjuntos, um conjunto contendo 75% dos dados, o qual será utilizado para realizar o treinamento da rede, e um segundo conjunto com 25% dos dados, que será utilizado para efetuar a validação da rede neural artificial.

A configuração e treinamento da rede neural artificial foram realizados com a utilização do software *EasyNN versão 8.01* (WOLSTENHOLME, 2004). A estrutura da rede foi definida como multicamadas e utilizou-se o algoritmo de retropropagação (*backpropagation*). Testes preliminares foram realizados para avaliar o desempenho de diferentes configurações de redes, sendo modificados alguns parâmetros, como o número de neurônios em cada camada, e analisando posteriormente o tempo de treinamento de cada uma das configurações verificadas. A opção que melhor se adequou foi a arquitetura que continha uma camada de entrada (valores RMS dos sinais), duas camadas ocultas e uma camada de saída para determinar o estágio de desgaste da ferramenta. A tabela 6.1 mostra a configuração e os valores dos parâmetros de treinamento utilizados na definição da rede.

Tabela 6.1 – Configuração e parâmetros de treinamento da RNA.

Descrição	Valor
Número de neurônios na primeira camada oculta	4
Número de neurônios na segunda camada oculta	2
Taxa de aprendizagem (<i>learning rate</i>)	0,60
Erro alvo (<i>target error</i>)	0,05

Os valores RMS foram utilizados como parâmetros de entrada para o treinamento e validação da rede neural, e a resposta da rede fornece a indicação do estágio de desgaste da ferramenta.

Para identificar os diferentes níveis de desgaste, resultado da classificação ou distinção entre as diferentes situações, designou-se como saída da rede neural, os valores mostrados na tabela 6.2.

Tabela 6.2 – Saída da RNA para os diferentes estágios de desgaste da ferramenta.

Estágio do desgaste	Saída desejada (meta) da RNA
Inicial	0.00
Intermediário	0.35
Avançado	0.70
Crítico	1.00

O treinamento da rede foi realizado informando os parâmetros de entrada (dados extraídos dos ensaios realizados) e os parâmetros de saída, ver tabela 6.2. Após o treinamento, foram efetuados testes de validação do treinamento da rede. Foram fornecidos os dados de entrada “desconhecidos”, retirados dos ensaios separados para a fase de validação e calculado as saídas da rede. A saída da rede corresponde ao estágio de desgaste da ferramenta, que foi comparado com o valor correspondente, visto que se dispunha dos dados corretos (fase de validação) obtidos nos experimentos.

Para análise da saída da rede neural, os valores obtidos como resposta da rede foram definidos como “Status da rede”, (fase de validação dos dados) e os valores esperados ou desejados de saída da rede (treinamento) foram definidos como “Status real (verdadeiro)”, tabela 6.2.

Os dados de treinamento da rede neural, utilizando os valores RMS dos sinais de vibração são mostrados na Tabela 1 – Anexo 1.

A Figura 6.10 mostra os resultados obtidos para a ferramenta com cobertura de nitreto de titânio, rotação de 1250 rpm. Neste caso, a rede foi treinada com os valores RMS dos sinais de vibração, do conjunto de dados do treinamento, e posteriormente, foi avaliada com o conjunto de dados de validação.




Figura 6.10 – Status da rede utilizando o primeiro conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm

A rede foi capaz de identificar com precisão os estágios de desgaste. Para o estágio inicial de desgaste (Status real = 0,00) o Status da rede foi de 0,0024 e para o estágio intermediário (Status real = 0,35) obteve-se como resposta o valor 0,3497, resultando numa diferença de menos de 1% em relação ao valor esperado. Para os estágios de desgaste avançado e crítico, a rede neural também foi capaz de identificá-los de forma satisfatória, porém com uma variação em torno de 2% em relação ao valor desejado, fornecendo como resposta os seguintes valores: Status da rede = 0,7681 para o estágio avançado e Status da rede = 0,9842 para o estágio crítico de desgaste.

As Figuras 6.11 a 6.13 ilustram os resultados obtidos para outros conjuntos de dados de validação.

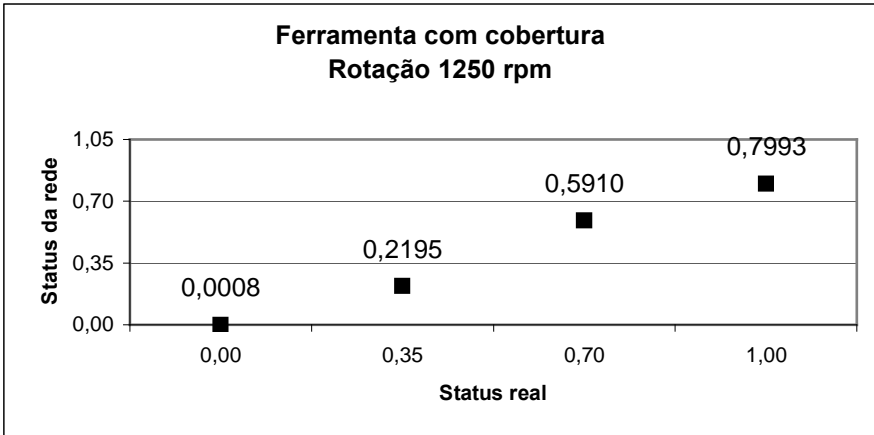


Figura 6.11 – Status da rede utilizando o segundo conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm




Figura 6.12 – Status da rede utilizando o terceiro conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm




Figura 6.13 – Status da rede utilizando o quarto conjunto de dados de validação, valores RMS, ferramenta com cobertura e rotação 1250 rpm

Analisando os resultados mostrados nas Figuras 6.10 a 6.13, utilizando diferentes conjuntos de dados de validação da rede, nota-se que, para o estágio inicial de desgaste (Status real = 0,00) o Status da rede foi em torno de 0,0007, resultado que mostra a correta e precisa identificação deste estágio de desgaste da ferramenta. Para o estágio de desgaste intermediário (Status real = 0,35) obteve-se como resposta valores cuja média foi de 0,3093, resultando numa diferença de cerca de 12% em relação ao valor esperado. Para o estágio de desgaste avançado, a rede neural também foi capaz de identifica-lo, porém em dois conjuntos de validação (Figuras 6.11 e 6.13), não foi possível a correta identificação, sendo que para os demais conjuntos, a rede identificou corretamente este estágio de desgaste, obtendo-se como

resposta valores cuja média foi em torno de 0,7636. No estágio crítico de desgaste, o valor médio do Status da rede foi de 0,9140, permitindo assim uma correta identificação desse estágio, resultando numa diferença em torno de 9% em relação ao valor esperado.

A tabela 6.3 mostra o percentual de acertos, a partir dos conjuntos de dados utilizados no processo de validação, utilizando valores RMS dos sinais de vibração, ferramenta com cobertura de nitreto de titânio e rotação 1250 rpm. Foram considerados como taxa de sucesso (acerto), os valores obtidos com uma diferença de $\pm 0,09$ em relação ao valor desejado. Essa taxa foi definida com os valores compreendidos no intervalo correspondente a $\pm \frac{1}{4}$ do valor estabelecido entre estágios de desgaste (ver tabela 6.2), considerando que com estes valores é possível representar corretamente os respectivos estágios de desgaste da ferramenta.

Tabela 6.3 – Comparação entre o percentual de acertos da RNA, treinada utilizando valores RMS dos sinais de vibração e rotação 1250 rpm, para a ferramenta com cobertura.

Estágio de desgaste	Saída desejada (Status real)	Percentual de acertos
		RMS
Inicial	0,00	100%
Intermediário	0,35	75%
Avançado	0,70	50%
Crítico	1,00	75%

6.4.2. DECOMPOSIÇÃO WAVELET DOS SINAIS DE VIBRAÇÃO – FERRAMENTA COM COBERTURA

Os sinais de vibração utilizados foram os mesmos sinais apresentados no item anterior, sendo que a estratégia de extração dos parâmetros para treinamento da rede é diferente. Neste caso, os sinais foram decompostos em detalhes e aproximações utilizando a transformada wavelet e os valores RMS dos coeficientes dos níveis de detalhes, foram utilizados como entrada da rede.

Utilizando o software *Matlab versão 5.3*, através da transformada wavelet discreta tipo *Daubechies*, disponível num dos “*toolbox*” do *Matlab*, foram extraídos os coeficientes wavelet dos sinais de vibração, os quais foram decompostos em quatro níveis, obtendo-se os

respectivos coeficientes wavelet, que correspondem às baixas e altas frequências (chamados de aproximações e detalhes, respectivamente). Os coeficientes detalhes foram utilizados no treinamento da rede neural. Para cada detalhe wavelet, calculou-se os respectivos valores RMS, que são utilizados como entrada na fase de treinamento e validação da rede neural. A figura 6.14 ilustra a decomposição wavelet do sinal de vibração.




Figura 6.14 –Representação esquemática da decomposição wavelet do sinal de vibração

A Tabela 2 – Anexo 1 mostra os valores RMS dos coeficientes wavelet utilizados como entrada no treinamento, bem como a saída desejada da rede neural.

Neste caso, a arquitetura da rede foi definida com duas camadas ocultas, tendo a primeira camada 5 neurônios e a segunda 3 neurônios. A camada de entrada contém 4 dados de entrada, valores RMS dos coeficientes detalhes obtidos a partir da transformada wavelet e a camada de saída contém a informação do estágio de desgaste da ferramenta. Os parâmetros de configuração da rede são mostrados na tabela 6.4.

Tabela 6.4 – Configuração e parâmetros de treinamento da RNA utilizando coeficientes wavelet

Descrição	Valor
Número de neurônios na primeira camada oculta	5
Número de neurônios na segunda camada oculta	3
Taxa de aprendizagem (<i>learning rate</i>)	0,60
Erro alvo (<i>target error</i>)	0,05

A utilização da transformada wavelet busca separar as informações importantes do sinal em coeficientes de baixa (aproximações) e de altas (detalhes) frequências. As informações de cada nível de detalhes serão condensadas com o cálculo do valor RMS deste nível, que posteriormente será utilizado para gerar a base de dados para o treinamento da rede. A decomposição do sinal em níveis e o uso destes no treinamento, busca a redução do número de dados medidos e conseqüente definição de uma base de dados que represente melhor os estágios de desgaste da ferramenta.

As Figuras 6.15 a 6.18 mostram os resultados obtidos utilizando ferramenta com cobertura, rotação 1250 rpm e os coeficientes wavelet como entrada da rede neural.




Figura 6.15 – Status da rede utilizando o primeiro conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm




Figura 6.16 – Status da rede utilizando o segundo conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm




Figura 6.17 – Status da rede utilizando o terceiro conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm




Figura 6.18 – Status da rede utilizando o quarto conjunto de dados de validação, coeficientes wavelet, ferramenta com cobertura e rotação 1250 rpm

Analisando os gráficos mostrados nas Figuras 6.15 a 6.18 nota-se que o estágio inicial de desgaste (Status real = 0,00) foi detectado, ou seja, a rede neural foi capaz de identificar com precisão este nível de desgaste, fornecendo como saída o valor médio do Status da rede = 0,0378. No estágio intermediário de desgaste (Status real = 0,35) o valor médio obtido como Status da rede foi de 0,4055, resultando numa diferença entre o valor desejado e o valor obtido em torno de 12%. No estágio avançado de desgaste, obteve-se uma variação, em relação ao valor desejado, de aproximadamente 6%, o que pode ser considerado plenamente satisfatório, pois se deseja obter como Status real o valor 0,75, sendo fornecido o valor médio do Status da rede = 0,7094. Para o estágio de desgaste crítico, obteve-se uma diferença em torno de 5%, sendo esperado o Status real = 1,00 e fornecido como Status da rede o valor médio de 0,9547.

A tabela 6.5 mostra o percentual de acertos da rede utilizando os valores RMS extraídos dos coeficientes wavelet, com a ferramenta com cobertura de nitreto de titânio e rotação 1250 rpm. Foram considerados como taxa de sucesso, os valores obtidos com uma diferença de $\pm 0,09$ em relação ao valor desejado.

Tabela 6.5 – Comparação entre o percentual de acertos da RNA, treinada utilizando valores RMS dos coeficientes wavelet e rotação 1250, para a ferramenta com cobertura.

Estágio de desgaste	Saída desejada (Status real)	Percentual de acertos
		Wavelet
Inicial	0,00	100%
Intermediário	0,35	100%
Avançado	0,70	100%
Crítico	1,00	100%

A figura 6.19 mostra a comparação dos resultados apresentados anteriormente (tabelas 6.3 e 6.5), utilizando as duas estratégias de extração dos parâmetros para o treinamento da rede, valores RMS dos sinais de vibração e RMS dos coeficientes wavelet, obtidos utilizando a ferramenta com cobertura e a rotação de 1250 rpm.




Figura 6.19 – Gráfico comparativo com os resultados obtidos utilizando valores RMS e coeficientes wavelet, para a ferramenta com cobertura e rotação 1250 rpm.

Os resultados obtidos utilizando os coeficientes wavelet mostram-se melhores que os valores RMS. Isto ocorreu porque com a transformada wavelet consegue-se separar o sinal de vibração em dados contendo baixas e altas frequências, os quais posteriormente são divididos em níveis, obtendo-se, conseqüentemente, conjuntos de dados contendo valores que podem indicar com mais precisão a evolução do desgaste em cada um dos níveis, enquanto que, utilizando os valores RMS, tem-se uma representação global de todos os valores contidos no sinal de vibração.

Comparando os valores mostrados na figura 6.19, verifica-se que para o estágio de desgaste inicial, a rede neural identificou com precisão, tanto para os valores RMS quanto para os coeficientes wavelet. No estágio intermediário de desgaste, o Status da rede obtido com os valores RMS, teve um grau de acerto de 75% em relação à saída desejada. A resposta obtida com os coeficientes wavelet resulta em acerto em torno de 100%, resultando num menor índice de acerto da rede treinada com os valores RMS dos coeficientes wavelet.

Os resultados obtidos no estágio avançado de desgaste, indicam que a rede neural identificou com maior precisão quando treinada com os valores RMS dos coeficientes wavelet. O nível de acerto da rede utilizando os valores RMS dos sinais de vibração, foi de 50%, enquanto que, para os valores RMS dos coeficientes wavelet, o nível de acerto foi de 100%, resultando num índice plenamente satisfatório de acerto.

Para o nível crítico de desgaste da ferramenta, o percentual de acerto da rede treinada com valores RMS dos sinais de vibração, foi de 75% e para o treinamento utilizando os coeficientes wavelet obteve-se 100% de acerto, para o conjunto de dados utilizados no processo de validação da rede.

De acordo com os resultados analisados, utilizando ferramentas com cobertura de nitreto de titânio e rotação de 1250 rpm, podemos realizar algumas conclusões:

- □ a rede neural no estágio inicial de desgaste, independentemente de utilizar valores RMS ou coeficientes wavelet no seu treinamento, identificou correta e satisfatoriamente o estágio de desgaste da ferramenta de corte, cujos percentuais de acerto foram 100%;
- □ no estágio de desgaste intermediário, a rede utilizando os valores RMS dos sinais de vibração obteve um nível de acerto menor que a rede treinada com os valores RMS dos coeficientes wavelet;
- □ no estágio avançado de desgaste, a rede neural utilizando os valores RMS dos coeficientes wavelet teve um nível de acerto de 100%, enquanto que, a rede treinada com os valores RMS dos sinais de vibração, obteve um nível de acerto de 50%;
- □ no estágio de desgaste crítico, momento no qual a ferramenta de corte deve ser substituída, verificou-se a que a rede utilizando os valores RMS dos coeficientes wavelet foi capaz de identificar de forma plenamente satisfatória o nível de desgaste, cujo comportamento não foi detectado na rede utilizando os valores RMS dos sinais de vibração;
- □ a rede neural foi capaz de identificar corretamente todos os estágios de desgaste da ferramenta, mostrando um melhor nível de acerto quando treinada somente com os valores RMS dos coeficientes wavelet.

6.4.3. VALORES RMS DOS SINAIS DE VIBRAÇÃO – FERRAMENTA SEM COBERTURA

Os testes discutidos acima foram também repetidos para uma ferramenta sem cobertura. A rede neural foi configurada utilizando os parâmetros especificados na tabela 6.1 e o conjunto de dados foi obtido durante os testes, com a ferramenta sem cobertura, utilizando as rotações de 1000 e 1250 rpm. Neste caso, foram utilizados como entrada da rede os valores

RMS dos sinais de vibração e os valores de saída são os estágios de desgaste, de maneira análoga ao caso anterior.

Inicialmente são apresentados os resultados obtidos utilizando a rotação de 1250 rpm, mostrados nas Figuras 6.20 a 6.23.




Figura 6.20 – Status da rede utilizando o primeiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm




Figura 6.21 – Status da rede utilizando o segundo conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm




Figura 6.22 – Status da rede utilizando o terceiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm




Figura 6.23 – Status da rede utilizando o quarto conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1250 rpm

A tabela 6.6 mostra o percentual de acertos, a partir dos conjuntos de dados utilizados no processo de validação, utilizando valores RMS dos sinais de vibração, para a ferramenta sem cobertura, com a rotação de 1250 rpm. Os valores obtidos com uma diferença de $\pm 0,09$ em relação ao valor desejado foram considerados como corretos (taxa de sucesso).

Tabela 6.6 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos sinais de vibração para a ferramenta sem cobertura e rotação de 1250 rpm.

Estágio de desgaste	Saída desejada (Status real)	Percentual de acertos
		RMS
Inicial	0,00	100%
Intermediário	0,35	25%
Avançado	0,70	0%
Crítico	1,00	100%

Analisando os valores mostrados na tabela 6.6, nota-se que no estágio de desgaste avançado a rede não foi capaz de identificá-lo corretamente, obtendo um índice de acerto de 0%. No estágio intermediário a rede não conseguiu identifica-lo corretamente, tendo um índice de acerto de 25%. Nos estágios de desgaste inicial e crítico, o percentual de acerto da rede foi satisfatório, resultando em acerto de 100% para os respectivos estágios de desgaste.

A próxima discussão é relativa ao conjunto de dados obtidos durante os testes com a ferramenta sem cobertura e utilizando a rotação de 1000 rpm, os quais foram utilizados para o treinamento da rede neural. Os resultados obtidos são mostrados nas Figuras 6.24 a 6.27.




Figura 6.24 – Status da rede utilizando o primeiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm




Figura 6.25 – Status da rede utilizando o segundo conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm




Figura 6.26 – Status da rede utilizando o terceiro conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm




Figura 6.27 – Status da rede utilizando o quarto conjunto de dados de validação, valores RMS, ferramenta sem cobertura e rotação 1000 rpm

A tabela 6.7 mostra o percentual de sucesso a partir dos conjuntos de dados utilizados no processo de validação, utilizando valores RMS dos sinais de vibração, para a ferramenta sem cobertura, com a rotação de 1000 rpm. O critério adotado como taxa de sucesso, foi o mesmo apresentado anteriormente, ou seja, valores obtidos com uma diferença de $\pm 0,09$ em relação ao valor desejado.

Tabela 6.7 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos sinais de vibração para a ferramenta sem cobertura e rotação de 1000 rpm.

Estágio de desgaste	Saída desejada (Status real)	Percentual de acertos
		RMS
Inicial	0,00	100%
Intermediário	0,35	0%
Avançado	0,70	75%
Crítico	1,00	100%

Os resultados apresentados na tabela 6.7, indicam que apenas o estágio intermediário de desgaste não foi identificado, resultando em 0% de acerto pela rede. No estágio de desgaste avançado obteve-se o nível de acerto de 75% em relação a saída desejada. Os resultados obtidos nos estágios de desgaste inicial e crítico, indicam que a rede neural identificou 100% dos valores utilizados na fase de validação.

A comparação entre as saídas da rede neural e os resultados reais obtidos nos ensaios de usinagem, utilizando ferramenta sem cobertura e rotações de 1000 e 1250 rpm, mostrados nas tabelas 6.6 e 6.7, resulta nas seguintes conclusões:

- □ Nos ensaios utilizando a rotação de 1250 rpm, a rede neural foi capaz de identificar os níveis de desgaste inicial e crítico de maneira satisfatória, com um índice de acerto de 100% em ambos os estágios; os níveis intermediário e avançado não foram identificados, obtendo um percentual de 0% de acerto, conforme mostrado nas Figuras 6.20 a 6.23.

□ □ Utilizando a rotação de 1000 rpm, conforme mostrado nas Figuras 6.24 a 6.27, a rede neural não conseguiu identificar corretamente o estágio intermediário de desgaste, resultando em 0% de acerto. No estágio de desgaste avançado, a rede foi capaz de identifica-lo, porém, com um percentual de acerto de 75% em relação ao valor desejado. Nos estágios de desgaste inicial e crítico, a rede foi capaz de identificá-los corretamente, atingindo um índice de acerto em 100%.

6.4.4. DECOMPOSIÇÃO WAVELET DOS SINAIS DE VIBRAÇÃO – FERRAMENTA SEM COBERTURA

Os sinais de vibração utilizados foram os mesmos sinais apresentados no item anterior, sendo que a estratégia de extração dos parâmetros para treinamento da rede é diferente. Neste caso, foram utilizados como parâmetro de entrada da rede neural, os valores RMS extraídos da decomposição wavelet dos sinais em quatro níveis, utilizando as rotações de 1000 e 1250 rpm e ferramenta sem cobertura, e espera-se obter como resposta o estágio de desgaste da ferramenta.

Neste caso, a arquitetura da rede foi definida com duas camadas ocultas, tendo a primeira camada 5 neurônios e a segunda 3 neurônios. A camada de entrada contém 4 dados de entrada, valores RMS dos coeficientes detalhes obtidos a partir da transformada wavelet e a camada de saída contém a informação do estágio de desgaste da ferramenta. Os parâmetros de configuração da rede são mostrados na tabela 6.8.

Tabela 6.8 – Configuração e parâmetros de treinamento da RNA utilizando coeficientes wavelet

Descrição	Valor
Número de neurônios na primeira camada oculta	5
Número de neurônios na segunda camada oculta	3
Taxa de aprendizagem (<i>learning rate</i>)	1,00
Erro alvo (<i>target error</i>)	0,05

Os resultados obtidos utilizando a rotação de 1250 rpm são mostrados nas Figuras 6.28 a 6.31.




Figura 6.28 – Status da rede utilizando o primeiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm




Figura 6.29 – Status da rede utilizando o segundo conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm




Figura 6.30 – Status da rede utilizando o terceiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm




Figura 6.31 – Status da rede utilizando o quarto conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1250 rpm

O percentual de sucesso a partir do conjunto de dados utilizados no processo de validação é mostrado na tabela 6.9, sendo utilizados os valores RMS dos sinais de vibração, ferramenta sem cobertura e rotação de 1250 rpm. Utilizou-se como critério para a definição da taxa de sucesso, o mesmo apresentado anteriormente.

Tabela 6.9 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos coeficientes wavelet para a ferramenta sem cobertura e rotação de 1250 rpm.

Estágio de desgaste	Saída desejada (Status real)	Percentual de acertos
		Wavelet
Inicial	0,00	100%
Intermediário	0,35	100%
Avançado	0,70	100%
Crítico	1,00	75%

Os resultados apresentados na tabela 6.9, indicam que apenas o estágio de desgaste crítico não foi identificado em todos os valores utilizados na fase de validação, resultando em 75% de acerto pela rede. Nos estágios de desgaste inicial, intermediário e avançado, obteve-se o nível de acerto de 100% em relação à saída desejada, resultando em uma taxa de acerto plenamente satisfatória.

Conforme discutido anteriormente, o conjunto de dados obtido durante os testes utilizando a rotação de 1000 rpm, com a ferramenta sem cobertura, foi utilizado para o treinamento da rede neural. Os resultados obtidos utilizando a rotação de 1000 rpm são mostrados nas Figuras 6.32 a 6.35.




Figura 6.32 – Status da rede utilizando o primeiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm




Figura 6.33 – Status da rede utilizando o segundo conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm




Figura 6.34 – Status da rede utilizando o terceiro conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm




Figura 6.35 – Status da rede utilizando o quarto conjunto de dados de validação, coeficientes wavelet, ferramenta sem cobertura e rotação 1000 rpm

O percentual de acertos a partir dos conjuntos de dados utilizados no processo de validação, utilizando a rotação de 1000 rpm, são mostrados na tabela 6.10. O critério adotado como taxa de sucesso, foi o mesmo apresentado anteriormente ($\pm 0,09$ em relação ao valor desejado).

Tabela 6.10 – Comparação entre o percentual de acertos da RNA treinada utilizando valores RMS dos coeficientes wavelet para a ferramenta sem cobertura e rotação de 1000 rpm.

Estágio de desgaste	Saída desejada (Status real)	Percentual de acertos
		Wavelet
Inicial	0,00	100%
Intermediário	0,35	0%
Avançado	0,70	75%
Crítico	1,00	100%

Com base nos resultados apresentados na tabela 6.10, pode-se concluir que:

- a rede neural treinada com os coeficientes wavelet foi capaz de diferenciar e identificar corretamente os níveis de desgaste da ferramenta, de maneira eficiente e com boa precisão, durante todo o processo de desgaste até o fim da vida da ferramenta, não identificando corretamente apenas o nível intermediário de desgaste;
- o estágio de desgaste avançado foi identificado com um percentual de acerto de 75% e os estágios crítico e avançado foram corretamente identificados, obtendo um percentual de acerto de 100% em relação aos valores esperados.

A Figura 6.36 ilustra o gráfico comparativo com o percentual de acertos da rede neural, utilizando a ferramenta sem cobertura, com base nos resultados mostrados nas tabelas 6.6 e 6.7, para a rotação de 1000 rpm.




Figura 6.36 – Gráfico comparativo com os resultados obtidos utilizando valores RMS e coeficientes wavelet, para a ferramenta sem cobertura e rotação 1000 rpm.

O gráfico comparativo com o percentual de acertos da rede neural, com base nos resultados obtidos utilizando a ferramenta sem cobertura e rotação 1250 rpm (tabelas 6.9 e 6.10), é mostrado na Figura 6.37.




Figura 6.37 – Gráfico comparativo com os resultados obtidos utilizando valores RMS e coeficientes wavelet, para a ferramenta sem cobertura e rotação 1250 rpm.

Verificando os valores mostrados nas Figuras 6.36 e 6.37, nota-se que no estágio inicial de desgaste, tanto a rede utilizando valores RMS, quanto a rede utilizando valores RMS extraídos dos coeficientes wavelet, mostrou um grau de acerto de 100% nas duas rotações empregadas nos ensaios (1000 e 1250 rpm).

No estágio intermediário de desgaste, a rede treinada com valores wavelet mostrou um nível de acerto muito maior do que a treinada com valores RMS, utilizando a rotação de 1250 rpm, resultando num nível de acerto de 100%. Os resultados obtidos utilizando a rotação de 1000 rpm, indicam que a rede neural não foi capaz de identificar o estágio intermediário de desgaste, tanto para a rede treinada com valores RMS dos sinais de vibração, quanto para a rede treinada com os valores RMS extraídos dos coeficientes wavelet, resultando em 0% de acerto. Isto ocorreu porque os valores utilizados no treinamento da rede neural, para o nível de desgaste intermediário, foram muito semelhantes aos valores do nível de desgaste avançado e, em alguns pontos, obteve-se valores praticamente idênticos, fazendo com que a rede não conseguisse identificar de forma correta o estágio intermediário de desgaste.

No estágio avançado de desgaste, os melhores resultados foram obtidos com as redes treinadas com os valores RMS dos coeficientes wavelet, resultando num nível de acerto de 75% para a rotação 1000 rpm e 100% para a rotação 1250 rpm; o resultado obtido com a rede utilizando valores RMS dos sinais de vibração, resultou num nível de acerto de 70% e 0% para as rotações de 1000 e 1250, respectivamente, mostrando claramente o maior nível de acerto da rede utilizando wavelet.

Os resultados obtidos no estágio crítico de desgaste, para a rotação de 1000 rpm, apresentam valores cujos níveis de acerto foram de 100% para os valores RMS dos sinais de vibração e também para os valores RMS dos coeficientes wavelet. Na rotação de 1250 rpm, os níveis de acerto identificados foram de 100% para os valores RMS dos sinais de vibração e 75% para os valores RMS dos coeficientes wavelet.

CAPÍTULO 7

7. CONCLUSÕES

A proposta deste trabalho é verificar a aplicação de redes neurais no monitoramento do desgaste de ferramentas de corte, através dos sinais de vibração e a correlação destes com as medidas de rugosidade da peça. Os sinais de vibração foram processados e analisados utilizando os valores RMS e Transformada Wavelet, neste caso, foram extraídos os valores RMS dos coeficientes wavelet. Os resultados apresentados e discutidos mostram, para os diferentes parâmetros de usinagem utilizados, que foi possível a identificação dos estágios de desgastes da ferramenta pela rede neural nos testes utilizando ferramenta de metal duro sem cobertura e com cobertura de nitreto de titânio

Com a ferramenta com cobertura, utilizando a rotação de 1250 rpm, os resultados mostram que a rede neural foi capaz de identificar corretamente todos os estágios de desgaste da ferramenta, sendo verificado um melhor nível de sucesso na identificação dos estágios de desgaste, quando treinada com os valores RMS dos coeficientes wavelet.

Para a ferramenta sem cobertura, com rotação de 1000 rpm, a rede treinada com os valores RMS dos sinais de vibração, conseguiu identificar os níveis de desgaste inicial, avançado e crítico, não identificando corretamente apenas o estágio de desgaste intermediário. Com a rotação de 1250 rpm, a rede identificou satisfatoriamente os estágios inicial e crítico. Utilizando os valores RMS dos coeficientes wavelet, os resultados mostram um nível de acerto elevado para os estágios de desgaste, em relação aos valores RMS dos sinais de vibração.

Portanto, comparando-se os resultados obtidos com a realização dos testes experimentais na fase de validação da rede neural, utilizando os valores RMS do sinal de vibração e RMS dos coeficientes wavelet, nota-se que a utilização dos coeficientes wavelet contribuiu para aumentar a capacidade de reconhecimento da rede. A rede neural tornou-se mais sensível quanto à identificação dos níveis de desgaste da ferramenta, mostrando que o parâmetro estágio de desgaste da ferramenta pode ser usado, de modo satisfatório, para aplicações no monitoramento da evolução do desgaste de ferramentas de corte no processo de torneamento.

7.1. SUGESTÕES PARA TRABALHOS FUTUROS

Para trabalhos futuros, propõe-se a realização de testes utilizando condições de usinagem diferentes das apresentadas neste trabalho, buscando identificar se existem grandes variações em relação aos resultados obtidos, de forma a permitir uma generalização da proposta para utilização em várias condições de usinagem. A implementação de um sistema real de monitoramento, baseado em medidas dos níveis de vibração, com a definição automática de níveis de alerta seria a próxima etapa do trabalho para sua, eventual, implementação em ambiente de fábrica.

REFERÊNCIAS

- BALAZINSKI, M.; CZOGALA, E.; JEMIELNIAK, K.; LESKI, J. Tool condition monitoring using artificial intelligence methods. **Engineering Applications of Artificial Intelligence**, v. 15, p. 73-80, 2002.
- BARRETO, J. M. Introdução às Redes Neurais Artificiais. Disponível em: <<http://www.inf.ufsc.br/~barreto/tutoriais.htm>>. Acesso em: 10 nov. 2003.
- BERNIERI, A.; D'APUZZO, M.; SANSONE, L.; SAVASTANO, M. A neural network approach for identification and fault diagnosis on dynamic systems. **IEEE Transactions on Instrumentation and Measurement**, v. 43, n. 6, p. 867-873, 1994.
- BONIFÁCIO, M. E. R. **Monitoramento do processo de torneamento de acabamento via sinais de vibração**. Campinas, 1993. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas.
- DAN, L., MATHEW, J. Tool wear and failure monitoring techniques for turning – a review. **International Journal of Machine Tools & Manufacture**, v. 30, p. 579-598, 1990.
- DEVILLEZ, A.; LESKO, S.; MOZER, W. Cutting tool crater wear measurement with white light interferometry. **Wear**, Article in Press, 2003.
- DIMLA, D. E. SNR. Sensor signals for tool-wear monitoring in metal cutting operations – a review of methods. **International Journal of Machine Tools & Manufacture**, v. 40, p. 1073-1098, 2000.
- DIMLA, D. E. SNR.; LISTER, P. M. On-line metal cutting tool condition monitoring. I: force and vibration analyses. **International Journal of Machine Tools & Manufacture**, v. 40, p. 739-768, 2000.

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da usinagem dos materiais**. 2. ed. São Paulo: Art Líber, 2000. 244p.

FERNANDES, F. A. N.; LONA, L. M. F. Desenvolvimento de resinas poliméricas usando redes neurais. In: 6º Congresso Brasileiro de Polímeros/ IX International Macromolecular Colloquium, 2001, Gramado (RS). **Anais...**

FERRARESI, D. **Usinagem dos metais**. São Paulo: Edgard Blücher, 1970.

HABER, R. E.; ALIQUÉ, A. Intelligent process supervision for predicting tool wear in machining processes. **Mechatronics**, v. 13, p. 825-849, 2003.

HARA, C. M. **Utilização de Redes Neurais na Análise de Sinais de Vibração de Ferramenta de Torneamento**. Campinas, 1995. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas.

KAMARTHI, S. V.; PITTNER, S. Fourier and Wavelet Transform for Flank Wear Estimation – A Comparison. **Mechanical Systems and Signal Processing**, v. 11, p. 791-809, 1997.

LEE, J. H.; KIM, D. E.; LEE, S. J. Application of Neural Networks to Flank Wear Prediction. **Mechanical Systems and Signal Processing**, v. 3, p. 265-276, 1996.

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

LIM, C.Y.H.; LAU, P.P.T.; LIM, S. C. The effects of work material on tool wear. **Wear**, v. 250, p 344-348, 2001.

LIU, Q.; ALTINTAS, Y. On-line monitoring of flank wear in turning with multilayered feed-forward neural network. **International Journal of Machine Tools & Manufacture**, v. 39, p. 1945–1959, 1999.

LOTTI, C.; BRETAS, R. E. S. Predição das propriedades mecânicas de polímeros moldados por injeção utilizando redes neurais artificiais. In: 6º Congresso Brasileiro de Polímeros/ IX International Macromolecular Colloquium, 2001, Gramado (RS). **Anais...**

MARTINS, M. P.; GUIMARÃES, L. N. F.; FONSECA, L. M. G. Classificador de Texturas por Redes Neurais. In: **II Congresso Brasileiro de Computação – CBComp**, 2002.

MATSUMOTO, H. **Uma Contribuição ao Estudo do Processo de Torneamento de Aços Endurecidos**. Campinas, 1998. Tese (Doutorado em Engenharia Mecânica) - Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas,.

NEWLAND, D. E. **Mechanical vibration analysis and computation**. New York: Longman Scientific & Technical, 1989. 583p.

ORTH, A. **Desenvolvimento de um sistema de visão para medir o desgaste de flanco de ferramentas de corte**. Florianópolis, 2001. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Santa Catarina.

ÖZEL, T.; NADGIR, A. Prediction of flank wear by using back propagation neural network modeling when cutting hardened H-13 steel with chamfered and honed CBN tools. **International Journal of Machine Tools & Manufacture**, v. 42, p. 287–297, 2002.

SANTOS, E. R. DE O. **Utilização da transformada Wavelet e Redes Neurais Artificiais para reconhecimento de padrões aplicados a manutenção preditiva**. Ilha Solteira, 2000. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista.

SANTOS, M. T.; ALMEIDA, A. R.; CHING TU, C. C. Redes Neurais Artificiais aplicadas no monitoramento da condição de ferramentas de corte utilizando algoritmo de extração das características SFS. In: **Congresso Brasileiro de Redes Neurais**, 4, 1999, p. 292-297, ITA, São José dos Campos – SP –Brasil.

SCHEFFER, C.; KRATZ, H.; HEYNS, P. S.; KLOCKE, F. Development of a tool wear-monitoring system for hard turning. **International Journal of Machine Tools & Manufacture**, v. 43, p. 973-985, 2003.

SILVA, I. N.; ARRUDA, L. V. R.; AMARAL, W. C.; BORDON, M. E. Projeto e Análise de uma Rede Neural para resolver problemas de programação dinâmica. **SBA Controle & Automação**, v. 12, n. 01, 2001.

SILVA, R. G.; REUBEN, R. L.; BAKER, K. J.; WILCOX, S. J. Tool wear monitoring of turning operations by neural network and expert system classification of a feature set generated from multiple sensors. **Mechanical systems and Signal Processing**, v. 12, p. 319-332, 1998.

TOMKIEWICZ, A. Z. Classifying the wear of turning tools with neural networks. **Journal of Materials Processing Technology**, v. 109, p. 300-304, 2001.

TÖNSHOFF, H. K.; WULFSBERG, J. P.; KALS, H. J. J.; RWTH AACHEN, C. A. VAN LUTTERVELT. Developments and Trends in Monitoring and Control of Machining Processes. *Annals of the CIRP*, v. 37, p. 611-622, 1988.

TOSUN, N.; ÖZLER, L. A study of tool life in hot machining using artificial neural networks and regression analysis method. **Journal of Materials Processing Technology**, v. 124, p. 99-104, 2002.

TRENT, E. M. **Metal Cutting**. 2nc. Edition, Butterwordths, London, 1984.

WASSERMAN, P. D. **Neural computing – Theory and Praticce**. New York: Van Nostrand Reinhold, 1989.

WEINGAERTNER, W. L.; SOUZA, A. J. Aplicação de um sistema de monitoramento inteligente no diagnóstico de falhas em ferramentas de corte: uma abordagem teórica. In: Congresso Nacional de Engenharia Mecânica, 2, 2002, João Pessoa. **Anais...**

WOLSTENHOLME, S. EasyNN 8.01. Disponível em: <<http://www.easynn.com/easynbase.html>>. Acesso em: 25 abr. 2004.

ZHOU, Q.; HONG, G. S.; RAHMAN, M. A new tool life criterion for tool condition monitoring using a Neural Network. **Engineering Applications of Artificial Intelligence**, v. 8, n. 5, p. 579-588, 1995.

ANEXO 1

Tabela 1 – Valores RMS e saída desejada, utilizados no treinamento da rede neural.

RMS dos sinais de vibração	
RMS	Saída
12,39	0.00
13,11	0.00
13,93	0.00
14,41	0.00
15,02	0.00
15,58	0.00
16,15	0.00
16,85	0.00
17,09	0.00
18,59	0.00
18,72	0.00
19,92	0.00
22,70	0.35
23,69	0.35
23,92	0.35
24,42	0.35
23,30	0.35
23,62	0.35
24,74	0.35
25,06	0.35
21,95	0.35
23,56	0.35
24,75	0.35
29,13	0.35
23,60	0.35
21,64	0.35
22,52	0.35
22,62	0.35
22,31	0.35
23,80	0.35
23,27	0.35
23,61	0.35
27,45	0.70
28,74	0.70
29,99	0.70
33,34	0.70
22,70	0.70
22,83	0.70
24,47	0.70

21,89	0.70
22,51	0.70
24,15	0.70
25,28	0.70
26,26	0.70
27,38	0.70
28,44	0.70
34,61	0.70
45,91	0.70
36,16	0.70
37,26	0.70
30,34	0.70
29,10	0.70
31,16	1.00
33,56	1.00
34,46	1.00
37,28	1.00
36,45	1.00
41,44	1.00
48,42	1.00
54,12	1.00
33,53	1.00
29,01	1.00
37,51	1.00
33,97	1.00
31,95	1.00
30,30	1.00
32,46	1.00
28,16	1.00
39,72	1.00
32,73	1.00
41,17	1.00
48,24	1.00

Tabela 2 – Valores RMS dos coeficientes wavelet e saída desejada, utilizados no treinamento da rede neural

RMS dos níveis de decomposição Wavelet				
Nível1	Nível2	Nível3	Nível4	Saída
12,4239	15,6425	10,3564	5,2746	0.00
12,8815	16,3434	12,3187	5,1043	0.00
13,1606	18,0585	12,6789	5,6774	0.00
15,0447	19,1845	13,1837	5,6048	0.00
15,3559	19,4476	13,9086	5,8760	0.00
15,8524	21,0533	12,8264	5,8095	0.00
15,7468	21,5869	12,5854	5,8596	0.00
18,0974	20,7422	11,0035	5,9608	0.00
23,6015	26,8971	14,3964	7,1616	0.35
27,1126	26,9200	14,7542	6,5338	0.35
21,2841	27,2598	15,5768	7,2366	0.35
23,9055	25,3934	14,9261	5,7369	0.35
28,8294	31,1852	23,6325	12,4562	0.35
24,3187	28,5438	15,6694	6,4205	0.35
24,3783	28,6909	14,3726	8,1054	0.35
27,5025	30,2347	20,8837	8,7944	0.35
24,1547	29,4762	16,3953	6,9568	0.35
26,7360	30,6503	16,6522	6,7361	0.35
23,6045	34,0915	27,4321	12,8683	0.35
25,0955	29,3612	16,5999	6,5182	0.70
29,5073	35,9479	24,9572	11,2548	0.70
23,5584	26,2276	15,9327	8,6816	0.70
25,4797	31,5413	18,4107	7,3385	0.70
25,2793	29,9054	16,1501	6,8529	0.70
23,1693	29,9433	14,3753	6,8002	0.70
23,7154	29,7749	16,3352	6,6197	0.70
24,9150	35,3307	18,8679	7,2256	0.70
30,7650	40,1937	20,8899	9,2007	0.70
44,8807	56,2477	23,4164	9,1079	1.00
73,9860	84,3172	68,8118	65,1275	1.00
37,7042	51,0462	25,6438	8,9770	1.00
33,2894	35,5338	17,9552	6,3408	1.00
32,0738	39,0730	18,3250	7,4407	1.00
33,1349	39,1724	19,1129	6,8967	1.00
36,6693	77,5788	71,1054	37,0019	1.00
49,8088	61,7082	38,4820	13,0221	1.00
44,6910	48,5185	23,4747	9,5438	1.00
34,9296	46,9647	26,8832	11,6290	1.00
24,4693	30,5033	17,6690	6,8834	1.00
38,4316	45,4098	22,0297	9,0462	1.00
28,8050	42,0542	21,2263	8,6122	1.00
80,0433	90,2419	83,9181	32,3452	1.00
28,5000	37,4233	21,9008	6,8024	1.00
39,7968	49,9079	26,7361	13,8137	1.00
33,9186	43,2046	24,2151	23,2019	1.00

Livros Grátis

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

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

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

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

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