



DETECÇÃO DO DESGASTE EM FRESAS FRONTAIS UTILIZANDO REDES NEURAI ARTIFICIAIS

Marcelo Teixeira dos Santos

Instituto Superior de Tecnologia – IST
Sociedade Educacional de Santa Catarina – SOCIESC
Rua Albano Schmidt, 3333 – Boa Vista, 89227700, Joinville, SC

Ailson Rosetti de Almeida

Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo
C.P. 01-9011, 29060-970, Vitória, ES

Carlos Chien Ching Tu

Departamento de Engenharia Mecânica, Escola Politécnica da Universidade de São Paulo,
C.P. 8174 - 01065-970, Cidade Universitária, São Paulo, SP

***Resumo.** O estudo da viabilidade de um sistema de monitoramento do desgaste da ferramenta no processo de fresagem de topo é baseado em técnicas de redes neurais e processamento de sinais. Demonstra-se a aplicação destas técnicas através do emprego de um acelerômetro e um sensor de corrente. Comprova-se que a aplicação de técnicas de inteligência artificial baseadas em Redes Neurais Artificiais (RNA) aliadas ao algoritmo de Codificação Preditiva Linear (LPC) torna possível o uso de sensores de baixo custo e com bom desempenho. O processo de fresagem de topo é o processo de usinagem monitorado neste trabalho por ser, entre os processos de usinagem, o que apresenta um comportamento altamente não-linear. Como alternativa ao pré-processamento de sinais é aplicada a LPC por sua robustez, velocidade de computação, reduzida dimensão e estreita relação com o espaço de frequências. Utiliza-se do poder das Redes Neurais Artificiais para a detecção do desgaste da ferramenta.*

***Palavras Chaves:** Redes Neurais Artificiais, LPC, Desgaste, Ferramentas.*

1. INTRODUÇÃO

Uma das mais difíceis tarefas no processo de usinagem é a detecção do desgaste da ferramenta. Os primeiros estudos de desgaste de ferramenta de corte em operações de arranque de material foram realizados para um dos processos mais básicos em usinagem, o processo de torneamento. Taylor foi pioneiro introduzindo a equação que relaciona a vida média da ferramenta com a velocidade de corte, mas que no entanto não leva em consideração as não-linearidades de um processo, causando um considerável erro na estimativa do tempo da vida útil de uma ferramenta. No princípio dos anos setenta (Wager & Barasch, 1971),

dentro da natureza estocástica do desgaste da ferramenta, mostrou que podem ocorrer variações de uma à nove vezes na vida de uma ferramenta sob condições nominais. Também em (Zakaria & Gomayel, 1975) se conclui que somente a medição da temperatura (por meio de um *thermocouple voltage*) não seria suficiente para monitorar o desgaste de ferramentas, pois variações não correlacionadas ao desgaste, como por exemplo, mudanças na profundidade de corte do material, ou a ocorrência de pontos duros no material, também geram sensíveis diferenças no gradiente de temperatura, causando erros na estimativa da taxa de desgaste da ferramenta.

De acordo com a literatura, um grande número de métodos foram desenvolvidos para o monitoramento dos processos de usinagem. Não está claro entretanto, qual destes métodos possui melhor desempenho. De fato a maior parte das literaturas apresentam métodos específicos para cada aplicação. Os desempenhos dos métodos em termos de uma taxa de êxito, sensibilidade e robustez não são normalmente investigados.

Acompanhando a tendência nas pesquisas de sistemas de monitoramento publicadas pelo *Tool Condition Monitoring Working Group* (Byrne, Dornfeld, Inasaki, Ketteler, König & Teti, 1996), como principais avanços durante os anos noventa se pode citar o uso de múltiplos sensores para o aumento da credibilidade da resposta do sistema, o desenvolvimento de sensores inteligentes com a melhoria do processamento do sinal e capacidade de tomada de decisão e a implementação de sistemas sensoriais em controladores de arquitetura aberta para o controle das máquinas-ferramentas.

Atualmente, os sensores mais empregados em processos de usinagem são os sensores de força, de potência e os sensores de emissão acústica. Entretanto constata-se que os sistemas de monitoramento não foram implementados na indústria para trazer somente melhorias. Junto com a nova tecnologia surgiram novas incertezas nas mentes dos especialistas em usinagem com respeito ao “o que está sendo medido?” e “qual sistema sensorial é o mais apropriado?” Uma segunda razão, que pode tornar inadequada a tecnologia sensorial ao processo de usinagem, está relacionada às dificuldades que aparecem devido a defeitos de interface ou a erros do operador da máquina-ferramenta no ajuste inicial do sistema de monitoramento instalado. E finalmente as divergências que existem quanto a utilidade do sistema de monitoramento. Por exemplo, os construtores de máquinas-ferramentas preferem aplicar estes sistemas à proteção da máquina-ferramenta contra eventos ou falhas inesperadas. A conclusão que se chega dentro deste panorama é que o maior problema encontrado ainda é a incorreta interação que ocorre entre o sistema e o usuário, levando este muitas vezes a desconectar o sistema de monitoramento do ambiente produtivo. Assim sendo, a fase de treinamento de operadores de máquinas-ferramentas no momento da implantação destes sistemas é de vital importância para que o retorno deste investimento seja positivo.

Dentro deste contexto, estabeleceram-se alguns requerimentos mínimos aos sensores aplicados ao monitoramento do processo de usinagem:

- a) medição tão perto do ponto de usinagem quanto possível;
- b) a não redução da rigidez estática e dinâmica da máquina ferramenta;
- c) a não restrição do espaço de trabalho e parâmetros de corte;
- d) livre de manutenção e desgaste, facilidade na troca e baixo custo;
- e) resistente às partículas de poeira, cavacos, e influências mecânicas, eletromagnéticas e térmicas;
- f) funcionalidade independente da ferramenta e peça;
- g) características metrológicas adequadas;
- h) confiança na transmissão do sinal.

Levando-se em consideração estes requerimentos, somente uma pequena parcela dos sensores existentes no mercado seriam apropriados ao monitoramento das condições da ferramenta durante a usinagem.

Procurando seguir estas especificações, apresenta-se um sistema composto por um acelerômetro, medindo a vibração na direção de corte da ferramenta, e por um sensor de corrente, conectado ao cabo de alimentação do motor de acionamento do eixo árvore. Na seleção destes sensores considerou-se o seu valor comercial, o nível de interferência física no processo, e a facilidade de manutenção.

Assim, aplica-se um sistema para o monitoramento das condições da ferramenta procurando cumprir as seguintes exigências:

- a) redução do tempo de resposta do sinal;
- b) uma razoável credibilidade operacional;
- c) ampla capacidade de integração ao sistema de manufatura;
- d) alta robustez;
- e) baixos custos de instalação;
- f) simplicidade na atualização;
- g) requerimento de pequenos espaços;
- h) mínimas modificações para a instalação no processo de manufatura;
- i) pouca manutenção

Assim, este artigo apresenta a aplicação de um sistema de monitoramento ao processo de usinagem. Para o pré-processamento do sinal aplica-se a Codificação Linear Preditiva, mais conhecida como **LPC** ("*Linear Predictive Coding*"). Como algoritmo computacional para a detecção do desgaste da ferramenta implanta-se uma Rede Neural Artificial (**RNA**) do tipo "*feed-forward*", onde sua eficiência é calculada por um índice de acerto. Nos resultados experimentais se constatará a eficiência do monitoramento através da **RNA** para diferentes condições de usinagem, e de configuração do sistema sensorial. Assim, proporciona-se uma comparação entre a aplicação destes dois sensores e a combinação destes num arranjo multi-sensorial.

2. DESCRIÇÃO DO PROCESSO

O tipo de fresagem monitorado neste estudo é o processo de ranhurado. A máquina utilizada foi um centro de usinagem de fabricação espanhola, ANAK-MATIC-2000-CNC. As ferramentas de aço rápido, (sem revestimento), empregadas foram as fresas de vinte e cinco milímetros e de dezesseis milímetros de diâmetro, ambas com dois dentes, de marca Vallorbe (F1205-25, F1205-16). Os corpos de prova utilizados são de duro-alumínio (T7075).

Como sistema de aquisição de dados utilizou-se uma placa de aquisição da *National Instruments, AT-MIO-16E-2*. Os sinais obtidos para este trabalho são de um sensor de corrente por efeito Hall, marca Sandvik, "Fig. 1", acoplado à alimentação elétrica do motor do eixo árvore da máquina-ferramenta, e por um acelerômetro de marca *Bruel & Kjaer*, "Fig. 2" acoplado à parte externa da camisa do eixo árvore. Apesar de seus dados não terem sido utilizados para este trabalho, uma plataforma dinamométrica marca *Kistler* também foi utilizada para medir os esforços de corte nos eixos X, Y e Z da máquina ferramenta durante o processo de usinagem, para verificar o grau de correlação entre seus sinais e o sinal do sensor de corrente no motor do eixo árvore (Dos Santos *et al.*, 1996).

Os parâmetros de usinagem foram determinados de maneira que a taxa de remoção de material correspondente apresentasse ampla faixa operacional, permitindo a observação dos diversos comportamentos que o processo de ranhurado pudesse apresentar. Três conjuntos de

seqüências temporais abrangendo 72 combinações dos parâmetros de corte (profundidade de corte, a_p , velocidade de avanço, V_f , e velocidade de rotação, s), foram adquiridos para cada uma das ferramentas, como apresentado na "Tabela 1".



Figura 1 – Sensor de corrente conectado a alimentação do eixo árvore.

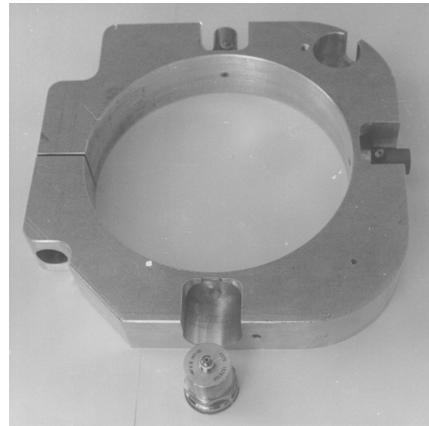


Figura 2 – Detalhe do dispositivo que envolve a camisa externa do eixo árvore para a fixação dos acelerômetros.

Tabela 1. Parâmetros de usinagem.

Diâmetro da Fresa (mm)	16	25
Profundidade de Corte, a_p (mm)	2, 5, 8	5, 8, 10 e 12
Velocidade de Avanço, V_f (mm/min)	20, 40, 60, 80, 100, 120, 150, 175, 200	40, 60, 80, 100, 120, 150, 175 e 200
Velocidade de Rotação, s (rpm)	600, 800, 1200, 1300, 1400, 1500	380, 500, 600, 800

Os três conjuntos de seqüências provenientes de usinagens, com as mesmas combinações de a_p , V_f , e s , foram obtidos das mesmas ferramentas ao longo de toda sua vida útil, enquanto seu estado de desgaste, classificado pelo operador, se encontrava nas seguintes regiões: **nova**, **semi-nova** e de **desgaste avançado**. A frequência de amostragem foi de 20 kHz, e as seqüências formadas por 4096 amostras com resolução de 12 bits.

3. CARACTERÍSTICAS DO SINAL

A "Figura 3" mostra a seqüência do sinal do sensor de corrente com 4096 amostras. Nota-se neste sinal o forte efeito indesejável proveniente da retificação trifásica não filtrada da alimentação elétrica do motor DC com controle de velocidade regulado por chaveamento tiristorizado. A variação do esforço sofrido pela ferramenta, que é a informação desejada, modula a corrente do motor. Como os espectros destes sinais se sobrepõem, torna-se impossível sua separação. Além do mais, o efeito é altamente não linear, visto que uma variação no esforço sofrido pela ferramenta afeta as características da onda de corrente do motor (pela variação do ângulo de disparo dos tiristores), para a regulação da velocidade. Ainda que alguma parte da informação relevante esteja situada no envelope do sinal, "Fig. 3", onde os picos representam a entrada dos dentes da ferramenta no material, boa parte está inseparavelmente misturada pela modulação.

A "Figura 4" mostra o espectro correspondente ao sinal da "Fig.3". Observa-se a grande concentração de potência indesejável nas frequências harmônicas da rede, principalmente em 300 Hz e seus múltiplos devido a retificação trifásica ($2 \times 3 \times 50\text{Hz}$, segundo experimentos realizados no Instituto de Automação Industrial - CSIC, Espanha), reforçando as considerações anteriores.

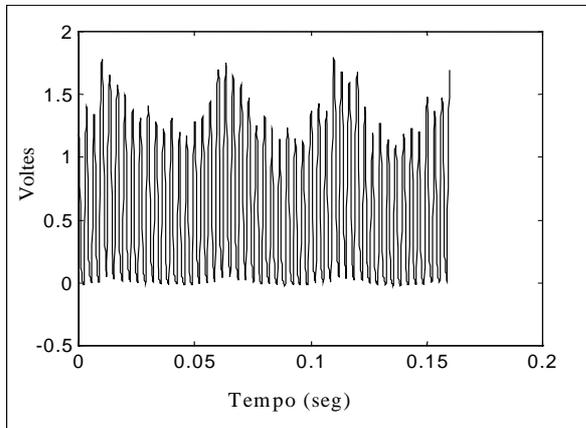


Figura 3 – Sinal do sensor de corrente.

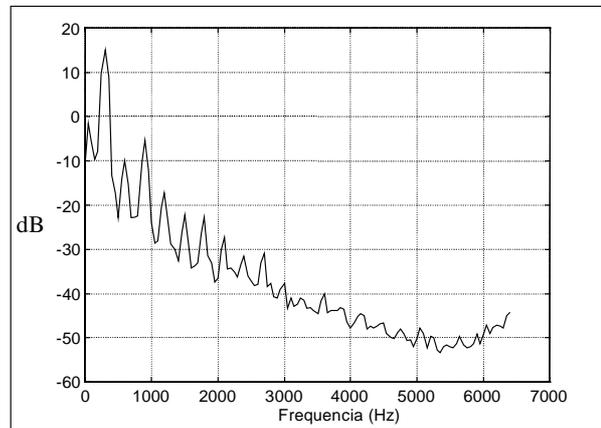


Figura 4 – Espectro do sinal do sensor de corrente

No caso do acelerômetro mede-se a vibração provocada pela fresa durante a usinagem. A "Fig. 5" mostra o comportamento deste sinal no domínio do tempo, e a "Fig. 6" mostra o espectro correspondente ao sinal deste sensor.

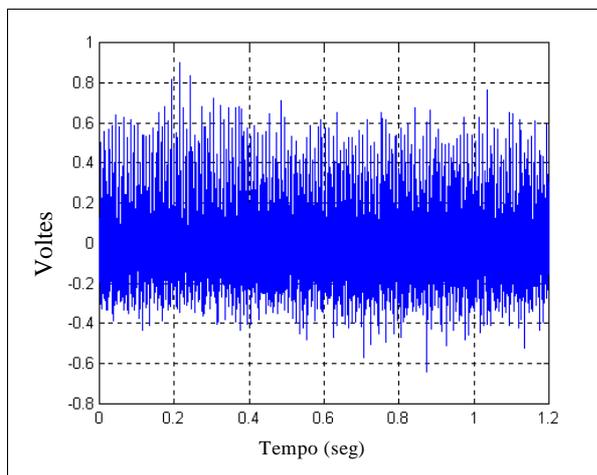


Figura 5 – Sinal do Acelerômetro

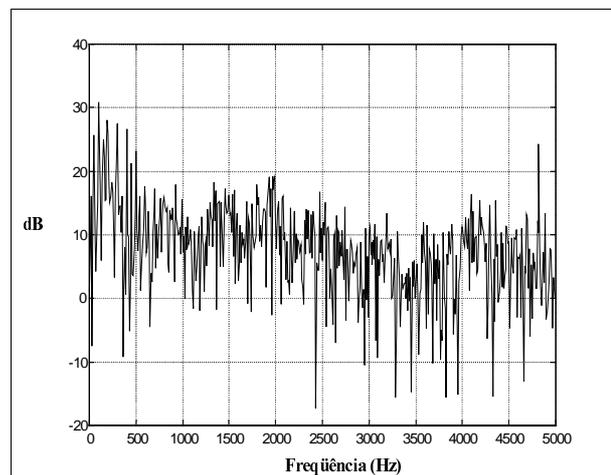


Figura 6 – Espectro do Sinal do Acelerômetro

4. PRÉ-PROCESSAMENTO

São três as finalidades do pré-processamento:

- mapear a seqüência temporal para um espaço atemporal (frequência), permitindo o uso de redes neurais estáticas (não recorrentes),
- realizar uma redução de dimensionalidade através de codificação eficiente, e portanto,
- promover uma primeira extração de características, facilitando o processamento neural.

A técnica utilizada para o pré-processamento foi a Codificação Preditiva Linear (LPC), por sua estreita relação com a identificação autoregressiva (AR) de processos, com a vantagem da rapidez de computação. Tem raízes no processamento do sinal de voz, como codificação para eficiente transmissão e armazenamento, sendo contudo utilizada em várias outras áreas, como por exemplo na medicina, no processamento de eletrocardiogramas - ECG (Machado, 1995), e na engenharia civil, na identificação de abalos sísmicos.

A idéia fundamental é que em um intervalo de curta duração (dentro do qual o sinal pode ser considerado estacionário), a seqüência original $s(i)$ pode ser decomposta como:

$$s(i) = s'(i) + r(i) \quad (1)$$

sendo $s'(i)$ a parte autoregressiva (AR) de ordem p de $s(i)$, definida como o valor estimado, ou previsto, de $s(i)$ com base na combinação linear de seus p valores passados $s(i-k)$,

$$s'(i) = \sum_{k=1}^p a_k \cdot s(i-k) \quad (2)$$

e $r(i)$ é a seqüência de erro residual. O conjunto ótimo de coeficientes autoregressivos a_k , que melhor representa o sinal, é aquele para o qual a variância de $r(i)$ é mínima. Os coeficientes LPC, c_k , são definidos pela combinação de (1) e (2) em:

$$r(i) = s(i) - s'(i) = \sum_{k=0}^p c_k \cdot s(i-k) \quad (3)$$

onde $c_0 = 1$.

Em sua aplicação original como codificação para eficiente transmissão, para cada janela (intervalo) processada, são transmitidos os coeficientes LPC, c_k , bem como a seqüência residual $r(i)$ com largura da palavra (número de bits) bem inferior a da seqüência original, dada sua baixa variância (faixa dinâmica). Alternativamente, são transmitidos junto com os coeficientes LPC algumas poucas informações características do sinal necessárias para sua reconstrução. Para tais aplicações, uma ordem LPC ao redor de 10 é suficiente.

Transportando a equação (3) para o espaço da transformada z ,

$$S(z) = \left(\frac{1}{\sum_{k=0}^p c_k \cdot z^{-k}} \right) R(z) \quad (4)$$

Se os coeficientes **LPC** modelam o sinal suficientemente bem tal que podemos considerar a seqüência residual como sendo ruído branco de medição, então a parte entre parêntesis da equação (4) nos fornece diretamente o espectro de frequências do sinal $s(i)$. Portanto, o conjunto de coeficientes **LPC** não somente proporcionam uma redução de dimensionalidade (relativamente poucos coeficientes são necessários em relação ao tamanho da seqüência) bem como mapeiam o sinal para o espaço de frequência (atemporal). Entretanto, para o tipo de aplicação aqui considerada, onde a seqüência residual é descartada, faz-se necessária uma ordem **LPC** muito superior à usualmente adotada para as aplicações originais desta técnica acima mencionadas. Agrega-se a isso a debilidade da informação útil embutida no sinal, que só pode ser exposta através de ordem **LPC** elevada. A adoção da codificação **LPC** em lugar de um modelamento autoregressivo convencional deve-se à sua eficiência de computação.

A "Figura 7" mostra o espectro obtido pelo modelamento **LPC** de ordem 128 do mesmo sinal do sensor de corrente da "Fig. 3", que o leitor deve comparar com o espectro da "Fig. 4". A mesma comparação pode ser feita entre a "Fig. 6" e "Fig. 8", para o espectro do sinal do acelerômetro, "Fig. 5" e de seu modelo utilizando a **LPC**.

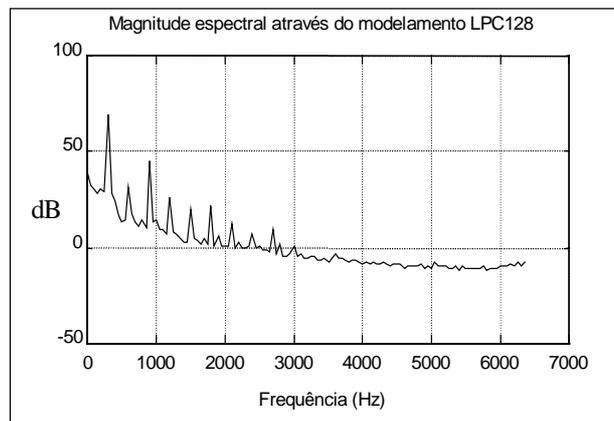


Figura 7 – Espectro LPC para o sensor de corrente.

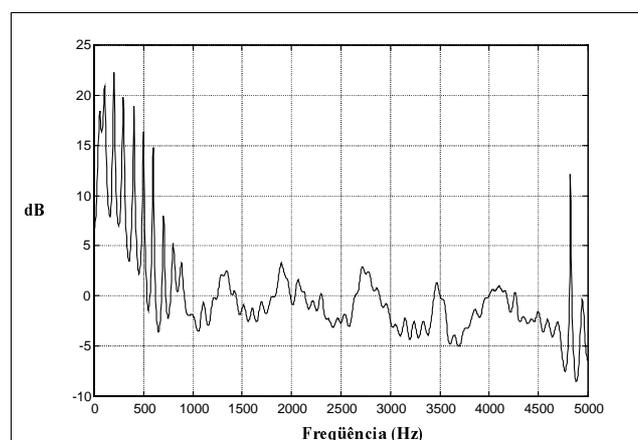


Figura 8 – Espectro LPC para o acelerômetro.

5. RESULTADOS DO PROCESSAMENTO NEURAL

Foi utilizada uma Rede Neural Artificial (RNA) do tipo *feed-forward*. A RNA do tipo *feed-forward* é submetida ao treinamento de diferentes combinações de parâmetros, tais como número de neurônios para cada camada oculta, número de camadas ocultas e tipo de função de ativação (sua *topologia*), geralmente como tentativa-e-erro. Uma rede demasiado pequena para a aplicação não será capaz de aprender satisfatoriamente (o algoritmo de aprendizado não converge para o mínimo estipulado), enquanto uma rede demasiado grande simplesmente decorará os exemplos do conjunto de aprendizagem, perdendo generalização. Um outro conjunto de exemplos, chamado *conjunto de validação*, é preparado, com o mesmo tamanho do conjunto de aprendizagem, sobre o qual são realizadas simulações de operação. Uma vez obtido um treinamento satisfatório, os pesos são fixados, e a rede está pronta para operar, desta vez respondendo a estímulos desconhecidos. Para os resultados da RNA apresentados a seguir a entrada é a seqüência amostrada dos sinais do sensor de corrente e do acelerômetro. Após pré-processamento, esta é transformada em um vetor p-dimensional, correspondendo aos coeficientes LPC, o qual se aplica como entrada para a rede neural. A saída é um valor binário representando o estado de desgaste da ferramenta.

Para a RNA foi convencionado uma saída bipolar (Almeida *et al.*,1997). A saída de valor +1 é para a ferramenta nova e -1 para a gasta, que funciona melhor que a contrapartida unipolar {0 1}, sendo esta uma das razões para a escolha da tangente hiperbólica como função de ativação. A saída da rede, quando em operação, apresenta um valor contínuo na faixa [-1 +1], que pode ser interpretado como probabilidade da condição da ferramenta, após translação e escala apropriadas. Por agora, o interesse é sobre o momento em que a ferramenta atinge um limiar de desgaste avançado (ou ocorre uma quebra repentina em seus dentes), indicando uma necessidade imediata de reposição. Para isso, é adicionado um comparador com limiar zero à saída neural na fase de operação (monitoramento do desgaste), tal que qualquer valor positivo na faixa [0 1] é considerado indicativo de uma ferramenta nova, enquanto uma saída negativa na faixa [-1 0] é considerada indicativa de uma ferramenta gasta. Qualquer limiar, contudo, pode ser usado, dependendo do critério de reposição de ferramenta adotado. Os resultados das provas apresentados na tabela 2 foram obtidos dos dados colhidos de duas ferramentas de corte como mencionado anteriormente.

Tabela 2. Parâmetros de processamento e desempenho

	Sensor de Corrente	Acelerômetro	Sensor de Corrente + Acelerômetro
Ordem LPC	128	128	128
No. de cam.ocultas	2	2	2
1ª camada oculta	20 neurônios	20 neurônios	20 neurônios
2ª camada oculta	6 neurônios	6 neurônios	6 neurônios,
Camada de saída	1 neurônio	1 neurônio	1 neurônio
Desempenho	87.50%	99.30%	95.17%

6. CONSIDERAÇÕES FINAIS

Dada a natureza adversa do sinal do sensor de corrente, consideramos o índice de desempenho de 87% bastante satisfatório, quando se está utilizando o mesmo modelo para o monitoramento do estado de ferramentas com distintos diâmetros. Com o acelerômetro se chegou a um excelente índice de desempenho de 99%. Isso só foi possível pela associação de um pré-processamento eficiente com a potência de uma RNA. A rápida detecção da condição de desgaste da ferramenta é muito importante para eficiência de produção e qualidade, em que

a ferramenta pode ser imediatamente reposta, reduzindo a taxa de rejeição de produto. Isso é de suma importância para processos de fresagem não atendidos (ou seja, totalmente automatizados). Na associação dos modelos LPC dos sinais dos dois sensores houve uma queda no índice de desempenho para 95%, quando comparado com o acelerômetro. Pode-se atribuir este índice mais baixo devido à introdução do sinal do sensor de corrente com suas altas não-linearidades e ruídos. Deste modo, demonstra-se a possibilidade da utilização de um único sensor, pois um eficiente pré-processamento em tempo e qualidade e conseqüentemente uma rede neural de reduzido tamanho, pôde ser facilmente implementada em um computador convencional para operação em tempo real.

A informação do estado de desgaste da ferramenta foi baseada no julgamento do operador. O conjunto de aquisições correspondentes ao estado **semi-nova** foi excluído neste processamento devido à natureza subjetiva deste estado, não tão evidente quanto aos extremos **nova** e **gasta**. Contudo, a avaliação do estado intermediário é importante porque os parâmetros de usinagem podem ser continuamente ajustados com base nesta informação. É possível aumentar a qualidade da peça usinada, por exemplo, mantendo-se tolerâncias mais estreitas em suas dimensões e melhorando o acabamento superficial.

Agradecimentos

Esta pesquisa foi realizada no Instituto de Automática Industrial (IAI) do Consejo Superior de Investigaciones Científicas (CSIC), Madrid, Espanha, com suporte do governo Espanhol através do Instituto de Cooperación Iberoamericana (ICI) e da Comunidade Europeia através do programa Keep In Touch KIT103-ARTVIS. Esta tornou-se também possível graças ao apoio da CAPES através do programa de doutorado com estágio no exterior. Os autores desejam agradecer o apoio obtido do Instituto de Automática Industrial e ao Centro de Mecânica de Precisão de Joinville. Este último mantido pela Sociedade Educacional de Santa Catarina, em Joinville, SC.

REFERÊNCIAS

- Almeida, A.R. & Dos Santos, M.T. (1997), "Neural Network-Based Tool Wear Monitoring In Milling Process Via Linear Predictive Coding", IFSA 97.
- Byrne, G., Dornfeld, D., Inasaki, I., Ketteler, G., König, W., e Teti, R. (1996), "Tool Condition Monitoring (TCM)-The Status of Research and Industrial Application", CIRP Annals, 1996.
- Dos Santos, M. T., Peres, C. R., Torrecillas, S. R., Alique, J. R., Alique, A (1996), "End Milling Process Stress Monitoring by Current Sensor," CSME'96, McMaster University, Canada, 07-09 May 1996.
- Machado, V. B. (1995), "Identificação Neural de Bloqueios Cardíacos", Tese de Mestrado, Univ. Federal do Espírito Santo - Dept. de Informática, dezembro de 1995.
- Wager, J.G. & Barash, M.M. (1971), "Study of the distribution of the life of HSS tools, Journal for Engineering Industry., 93, 1044.
- Zakaria, A.A. & El Gomayel, J.I. (1975), "On the Reliability of the Cutting Temperature for monitoring Tool Wear", Int. J. Mach. Tool Des. Res., 15, 195.

"TOOL WEAR DETECTION IN END-MILLING PROCESS VIA ARTIFICIAL NEURAL NETWORKS"

ABSTRACT:

This work addresses the viability study of a real time tool wear monitoring system for vertical end milling processes based on neural network techniques using, inexpensive, robust, non-invasive current sensor and accelerometers. The application of modern artificial intelligence techniques based on neural networks combined with properly chosen pre-processing algorithms makes possible the use of such low cost sensors with very acceptable detection performance. The selected pre-processing algorithm is the Linear Predictive Coding (LPC) for its robustness, speed efficiency, dimensionally reduction and its relation to the frequency space. For this first version, we used the Feedforward neural network paradigm, with Backpropagation as its learning algorithm. The tool wear detection results favour the application of this system to better production efficiency.

We show that, with properly chosen pre-processing algorithms combined with the power of neural networks, good tool wear monitoring results are obtained in spite of the sensory subsystem.

The milling process is described, so as the acquisition and sensorial system used for this work. Follows the LPC pre-processing with its advantage as a feature extractor, dimensionally reductor and its relation to the frequency space. Then, we make a brief presentation of neural networks focusing on the kind used, followed by the neural training methodology, design considerations and the network topology for the best training result obtained.

The fast detection of tool weariness condition is very important for production efficiency and quality, in that the tool can be rapidly replaced, reducing product rejection. This is of the most importance for fully automated, unattended milling processes. Due to the use of only one sensor (variable), efficient pre-processing algorithm in time and quality, and consequently small neural network size, the whole process can be easily implemented in a conventional computer for real time operation. Alternatively, the system can be implemented in a dedicated DSP processor for very fast detection of tool breakage, when the machining operation has to be immediately stopped in order to not damage the workpiece. Finally, we can improve even further the reliability and performance index if we vote considering three consecutive neural network decisions, avoiding false classifications due to momentary disturbances.

Keywords: Artificial Neural Net, Linear Predictive Coding, Cutting Tools, Wear.