

## Redes Neurais Artificiais Aplicadas no Monitoramento da Condição de Ferramentas de Corte Utilizando Algoritmo de Extração das Características SFS

Marcelo Teixeira dos Santos<sup>1</sup>, Ailson Rosetti de Almeida<sup>2</sup>, Carlos Chien Ching Tu<sup>3</sup>  
<sup>1</sup>Instituto Superior de Tecnologia IST Dep. de Automação Rua Albano Schmidt, 3333

89227700 Joinville SC

<sup>2</sup>Universidade Federal do Espírito Santo Dep. de Engenharia Elétrica, C.P. 01-9011  
29060-970 Vitória ES

<sup>3</sup>Universidade de São Paulo Dept. de Engenharia Mecânica, Cd.Universitária  
São Paulo SP

E-mails: teixeira@sociesc.com.br , ailson@ele.ufes.br, carlctu@usp.br

### Abstract

*The end-milling process is destined to pocketing and slotting operations in mechanical parts. The slotting process is one of the most common process in the mould manufacturing and it presents a highly non-linear behaviour. The application of the features extraction algorithms shows efficiency in the monitoring of tool wear. Using Artificial Neural Nets (ANN) configurations of monitoring system are determined to identify tool wear efficiently. The ANN chosen is the multilayer perceptron and the backpropagation algorithm is used as a learning method.*

### 1. Introdução

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 empíricos. Estes padrões de desgaste foram armazenados em seu cérebro através da experiência, adquirida ao longo dos anos de trabalho com o processo de corte do metal. A informação sensorial obtida para a tomada de decisão é 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. O fato é que operadores de máquinas-ferramentas na grande maioria dos 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 a peça usinada. Entretanto, é neste sistema em que se baseia o projeto do sistema de monitoramento sugerido, sendo

desenvolvido um algoritmo computacional que modela as habilidades de aprendizado e tomadas de decisão do operador [1].

Assim, através das informações geradas pelos sensores instalados num centro de usinagem foi acoplado ao sistema de monitoramento um sistema de tomada de decisões, o qual apropriadamente interpretará as informações de entrada do sensor associando-as aos padrões do estado da ferramenta. Aqui utiliza-se o algoritmo “*Sequential Forward Search*”, *SFS*, o qual previamente seleciona as características mais relevantes do comportamento do espectro do sinal dos sensores (da *força*, *corrente* e *aceleração*). A *Rede Neural Artificial*, *RNA*, é utilizada para integrar a informação das frequências selecionadas e reconhecer a ocorrência do desgaste da ferramenta numa operação de fresado. O treinamento da *RNA* possibilita a detecção do desgaste em um processo de fresado para uma faixa ampla de parâmetros de usinagem [2].

### 2. Processamento de Sinais e Extração das Características

O fluxograma do processamento do sinal é apresentado na *figura.1*. Foram escolhidos para análise: o sinal do sensor de corrente, da força na direção do avanço de fresado, e de dois acelerômetros, um posicionado no cabeçote do eixo árvore na direção do eixo de avanço e outro sobre a mesa. Os sinais dos sensores foram igualmente amostrados a uma taxa de *10kHz* para uma banda de frequência de *5kHz*. Com esta alta taxa de amostragem garantiu-se a qualidade dos sinais amostrados. Entretanto 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*, [1]. Com o objetivo de minimizar o tempo de processamento do algoritmo *SFS* os sinais armazenados foram reamostrados a uma

freqüência de 2kHz e o tamanho do vetor de aquisição foi reduzido de 2048 para 1024 elementos. Isto não afetou os resultados e contribuiu na diminuição do tempo de processamento dos dados no SFS (que passou de vinte e duas horas para doze horas em um computador com microprocessador Pentium 155). Assim, na realidade, obteve-se uma janela que ao longo do tempo coleta 1024 pontos de cada um dos sensores.

Calculando-se a Transformada Rápida de Fourier (TRF), é reproduzida a representação e variação do espectro de potência dos sinais gravados ao longo do tempo. Considerando-se o espectro de potência como um vetor cujas componentes são as potências do sinal nas várias freqüências discretas. Este vetor é denominado por vetor das medidas,  $\mathbf{d}$ , e suas dimensões dependem do tamanho da amostra coletada no tempo. Para o caso descrito aqui foram utilizados quatro sensores, levando o vetor das medidas,  $\mathbf{d}$ , a uma dimensão de 2048 linhas. A partir deste vetor de medidas construir-se-á a matriz de medidas, sendo que suas colunas estarão sendo relacionadas a cada uma das provas realizadas com seus respectivos parâmetros de corte.

Mesmo que a informação válida possa estar contida em toda a matriz de medição, por considerações práticas, somente alguns dos componentes do vetor de medição, podem ser usados para propósitos de treinamento e associação aos padrões. Para o treinamento de um classificador de padrões como o perceptron o uso de um vetor dimensional grande requer um número muito grande de padrões de treinamento, e na maioria dos casos, isto é impraticável, ou de custo elevado, [2].

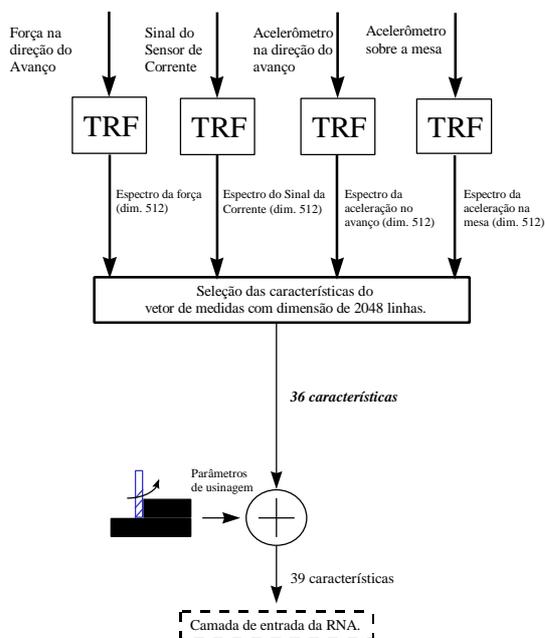


Figura 1: Diagrama para Processamento dos Sinais.

A redução da dimensão do vetor de medição é feita através da retenção daqueles componentes do espectro

que mostram uma alta sensibilidade ao desgaste da ferramenta e baixa sensibilidade aos ruídos e parâmetros do processo. Considerando que o vetor das medidas é de dimensão  $D$ , o objetivo é selecionar  $x$ 's características que maximizem um critério que represente a razão *signal/ruído* das características. As características selecionadas são componentes de um vetor de características de dimensão  $d$ . A função critério utilizada neste caso usa o conceito da medição da distância Euclidiana das intraclases e é discutida com detalhes em Devijver e Kittle, [3]. O critério estabelecido é descrito pela equação (1),

$$J = \frac{\text{traço}S_b}{\text{traço}S_w} \quad (1)$$

na qual  $S_w$  calcula a covariância interna da matriz de cada classe e  $S_b$  calcula a covariância entre as matrizes que representam as classes dos vetores das características de dimensão  $d$ . Ou seja,  $S_w$  mede a dispersão dos pontos de dados dentro de uma classe (nova ou desgastada) e  $S_b$  mede a distância entre os agrupamentos, representando os dados das ferramentas nova ou desgastada em uma característica espacial dimensional  $d$ . Intuitivamente, o valor de  $J$  representa a razão *signal/ruído* dos vetores de características. Sendo que  $S_w$  e  $S_b$  são calculados como descrito pelas equações 2 a, b e 3.

$$S_w = \frac{1}{r} \sum_{j=1}^k (\bar{X}_{ij} - \bar{X}_i)(\bar{X}_{ij} - \bar{X}_i)^T \quad (2-a)$$

$$S_w = \frac{1}{k} \sum_{i=1}^k W_j \quad (2-b)$$

$$S_b = \frac{1}{k} \sum_{i=1}^k (X_i - \bar{X})(X_i - \bar{X})^T \quad (3)$$

sendo que  $X_{ij}$  é o vetor de característica de dimensão  $m$  correspondente à  $j$ ésima amostra da  $i$ ésima classe;

$\bar{X}_i = \frac{1}{r} \sum_{j=1}^r X_{ij}$  é o vetor da média das  $j$ ésimas

características da  $i$ ésima classe;  $\bar{X} = \frac{1}{k} \sum_{i=1}^k \bar{X}_i$  é o

vetor da média de todas as classes; sendo  $r$  o número de amostras por classe e  $k$  o número de classes.

Para a comprovação experimental deste algoritmo em um processo de fresado, foram usados os dados adquiridos por uma fresa de topo de 25 mm de diâmetro. Desta obteve-se 72 vetores de medidas, correspondentes as várias condições de usinagem (para os estados da ferramenta *nova* e *desgastada*), que foram usados para estimar  $S_w$  e  $S_b$ . As características finais,  $\mathbf{d}$ , foram selecionadas usando o algoritmo "Sequential Forward Search" (SFS) de Whitney, [4]. O algoritmo trabalha extraindo das  $D$  características

armazenadas no vetor de medições a que maximize  $J$ . Denomina-se esta característica por  $\mathbf{z}_1$ . No próximo passo, são formados pares de cada uma das restantes  $D-1$  características com  $\mathbf{z}_1$  e calcula-se o  $J$  de acordo com a equação (1) para cada um destes pares. O par que maximiza  $J$ , é selecionado como um novo grupo de características. Este procedimento é repetido até que todas as características  $d$  tenham sido selecionadas. Pode-se dizer que o algoritmo *SFS* seja quase ótimo, pois não garante que as melhores características tenham sido selecionadas. Entretanto, este algoritmo é computacionalmente viável e produz um grupo de características cuja razão *signal/ruído* é razoavelmente próxima a um caso ótimo, [3]. Inicialmente fixou-se em 36 a dimensão para o vetor das características, ou seja, as 36 frequências que melhor representam o desgaste serão extraídas da matriz de medidas  $D$ .

Devido ao uso de vetores de medição correspondentes a diferentes condições do processo, as características selecionadas deveriam mostrar uma baixa sensibilidade às mudanças dos parâmetros do processo de usinagem. Entretanto, alguma sensibilidade ainda poderá estar presente. Assim, faz sentido utilizar-se os parâmetros do processo como característica adicional. Em alguns casos a informação da profundidade de corte pode ser de difícil obtenção, não permitindo seu uso como variável de entrada na RNA. Neste caso, as mudanças na profundidade de corte teriam o efeito de um ruído sobre os valores das características do sensor. Na seção seguinte são apresentados os resultados de diferentes processamentos em função das variáveis escolhidas como entrada da RNA.

Vários parâmetros de projeto afetam o desempenho do sistema de monitoramento de desgaste da ferramenta, como por exemplo: o número de amostras de treinamento, o número de sensores, as características dos sensores utilizados e a estrutura da RNA. Também a estrutura apresentada para o monitoramento do processo de fresado pode ser alterada conforme a aplicação que se destina.

### 3. Processamento Neural

O tipo de rede neural utilizada, por sua aplicabilidade universal, é o *perceptron multicamadas*, ou rede neural “*feedforward*”, composta por *camadas* de neurônios entre as camadas de entrada e saída, onde interconexões são permitidas somente das saídas dos neurônios de uma camada para as entradas dos neurônios da camada seguinte. O neurônio representado na figura 2 é modelado por:

$$y = f\left(\sum_{k=1}^n w_k \times x_k - b\right) = f\left(\sum_{k=0}^n w_k \times x_k\right) \quad (4)$$

no qual  $y$  é a saída,  $x_k$  ( $k=1,2,\dots,n$ ) são os elementos do vetor  $n$ -dimensional de entradas,  $b$  é um termo de polarização (transformado para o peso  $w_0$  correspondente a uma entrada fictícia  $x_0 = -1$  no lado mais à direita da equação (4)),  $w_k$  são pesos e  $f$  é conhecida como a função de ativação.

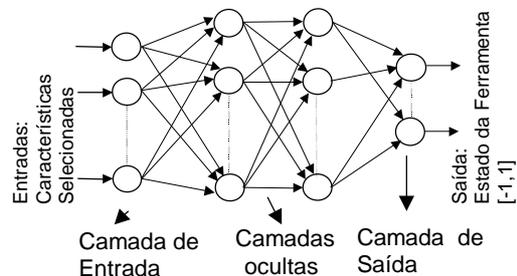


Figura 2: Rede Neural tipo Perceptron Multicamadas

O algoritmo de aprendizado utilizado e normalmente associado à rede neural “*feedforward*” é o “*backpropagation*”. Neste algoritmo de aprendizado o erro é propagado no sentido inverso da saída da rede com a técnica de *gradiente descendente de minimização* [5].

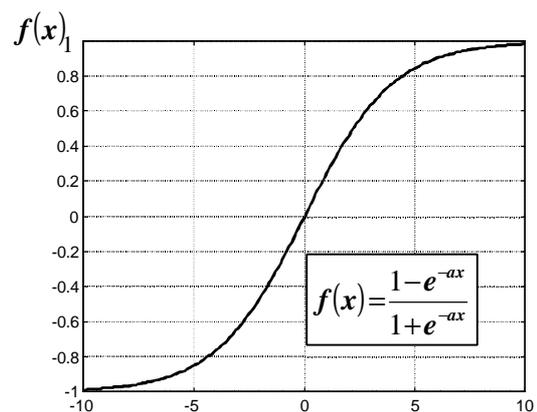


Figura 3: Função de ativação empregada.

A função de ativação empregada pertence à classe das *sigmoids*, figura 3, e é contínua monotônica, apresentando a não-linearidade necessária para mapeamento universal, [5].

A rede é treinada várias vezes, para diferentes topologias, ou seja, diferentes combinações de parâmetros tais como número de neurônios para cada camada oculta, número de camadas escondidas e tipo de função de ativação em um processo do tipo *tentativa-e-erro*. Uma rede muito pequena para a aplicação não será capaz de aprender satisfatoriamente (o algoritmo de aprendizado não converge para o mínimo estipulado), enquanto uma rede muito grande simplesmente armazenará os exemplos do conjunto de aprendizagem, perdendo a capacidade de generalização. Uma maneira popular de verificar a

generalização é preparar outro conjunto de exemplos, chamado *conjunto de validação*, aproximadamente do 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 estará pronta para operação na qual responderá a estímulos desconhecidos.

#### 4 Resultados Experimentais

Utilizando os dados adquiridos do processo de fresado para ferramentas consideradas *novas* e *desgastadas*, os sinais do sensor de corrente, da plataforma dinamométrica e de dois acelerômetros são processados segundo o algoritmo **SFS**, já descrito. Os resultados deste processamento são utilizados como entrada para a *RNA*, *figura 2*, e cuja rotina de cálculo foi idealizada para o software MATLAB, *seção 6*. A *RNA* em questão proporciona como saída valores entre 1 e -1, indicando uma ferramenta em boas condições de uso ou uma ferramenta com elevado desgaste, respectivamente.

As configurações das estruturas das *RNA's* do tipo "feedforward" aplicadas na detecção do desgaste da ferramenta foram definidas provando-se diferentes tipos de configurações na base da tentativa-e-erro. Na maioria das vezes utilizando-se uma camada oculta com o mesmo número de neurônios da camada de entrada, se alcança resultados satisfatórios no monitoramento do desgaste através das magnitudes das frequências selecionadas pelo algoritmo **SFS**. Caso os resultados com uma camada não sejam satisfatórios, aumenta-se o número de camadas ocultas melhorando a capacidade de aprendizado da *RNA*. Para o caso do monitoramento do desgaste da fresa de topo o número de camadas ocultas não passou de duas. A seguir são apresentados os resultados das provas de monitoramento do desgaste de uma fresa de topo com diâmetro de 25 mm.

Processando-se os dados adquiridos pelos sensores para a fresa de topo de 25 mm através do algoritmo **SFS**, retiveram-se as 36 características de frequências significativas ao desgaste desta ferramenta. O valor de *J*, na *tabela 1*, é o índice que determina a separabilidade entre as classes de uma ferramenta *nova*, ou em boas condições de uso, de uma ferramenta *desgastada*. Assim, quanto maior o *J* maior a separabilidade entre as classes, ou seja, maior será a confiabilidade na tomada de decisão para a determinação da condição da ferramenta.

As 6 primeiras características retidas da matriz de medidas *D*, listadas na *tabela 1*, são as frequências extraídas dos sinal da plataforma dinamométrica (*Força X*), e do sinal do acelerômetro também na direção do avanço (*Acelerômetro X*) da fresa de topo durante o processo de usinagem.

Tabela 1: Grupo de Características Seleccionadas do Espectro de Frequência para a Ferramenta de 25 mm e duas entradas.

Nº	Sensor	Característica (Hz)	J*
1	Acelerômetro X	349.61	5.58
2	Força X	93.75	5.15
3	Acelerômetro X	150.39	5.00
4	Força X	48.83	5.09
5	Força X	107.42	5.00
6	Força X	982.42	4.76

Na última coluna da *tabela 1* são apresentados os valores obtidos para *J*, os quais decrescem a partir do instante em que agregam-se novas características (*figura 5*). Pela teoria desenvolvida por **Dejiver** e **Kittler**, [3], os maiores valores para *J* indicam uma melhor condição de separabilidade entre as classes de ferramenta *nova* e ferramenta *desgastada*. Ou seja, a componente de frequência de 349,61 Hz do acelerômetro na direção do avanço da ferramenta, com *J* igual a 5,58, proporciona uma melhor condição para a identificação do desgaste da fresa de topo que as três frequências seguintes da *força X*, com o valor de *J* em torno de "5", por exemplo. Como já descrito por **Dornfeld**, [6], a adição das demais características de frequências degeneram a informação relativa à separabilidade entre as classes, a qual, a partir de então, não seria tão clara. O gráfico da *figura 4* ilustra o comportamento de *J* a medida que se adicionam as características de frequência selecionadas.

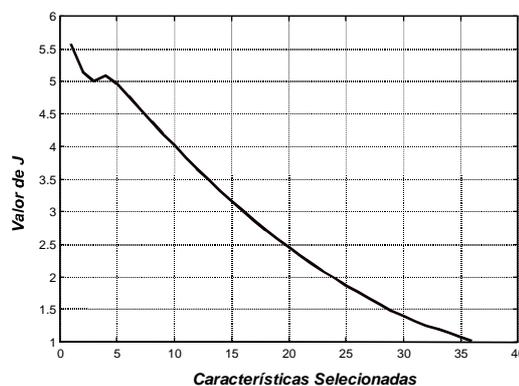


Figura 4: Variação do valor de *J* em função das características adicionadas utilizando a ferramenta de 25 mm de diâmetro.

No monitoramento do desgaste da fresa de topo 25 mm de diâmetro através do *acelerômetro-x* na componente de frequência de 349,61 Hz, utilizou-se uma *RNA* com quatro entradas (as magnitudes do sinal nesta frequência mais os três parâmetros de usinagem), com seis neurônios na camada oculta e um neurônio na camada de saída, designada por: *RNA 4x6x1*. Para o treinamento desta *RNA* utiliza-se o algoritmo "backpropagation" e os dados de entrada preenchem

uma matriz de *quatro linhas por 72 colunas*. Para a validação desta *RNA* utilizam-se outras 72 amostras da mesma fresa de topo adquiridas com valores distintos dos parâmetros de usinagem daqueles usados para as amostras do treinamento. O *índice de acerto* foi calculado pela expressão 5. Para este caso obteve-se um acerto de 100% na identificação do desgaste.

$$\text{Índice de Acerto} = \frac{\text{Número de Identificações corretas}}{\text{Número Total de Amostras}} \quad (5)$$

Simulando o caso de um sistema de monitoramento onde não seja possível a obtenção da profundidade axial da ferramenta em tempo real, treinou-se uma *RNA* com a configuração *3x6x1*. Eliminando os valores da profundidade de corte, as três entradas foram carregadas com os valores da magnitude da frequência de 349,61 Hz, os valores da velocidade de avanço e os valores da velocidade de giro da ferramenta. Treinando a *RNA 3x6x1*, no momento da validação, obteve-se um *índice de acerto* de 98,61% na detecção do desgaste.

Os valores dos parâmetros de usinagem para a fresa de topo de 25 mm de diâmetro e dois dentes, usados no treinamento e validação da *RNA 4x6x1* e *RNA 3x6x1* encontram-se na tabela 2.

Tabela 2: Parâmetros de corte utilizados.

Profundidade de Corte (mm)	5, 8, 10 e 12
Velocidade de Avanço (mm/seg)	80, 100, 120, 150, 175 e 200
Velocidade de Rotação (rpm)	380, 500, 600 e 800

## 5 Considerações Sobre o Uso do Algoritmo SFS/RNA no Monitoramento do Desgaste da Ferramenta

O que se apresenta e avalia neste artigo é a estratégia de construção de um sistema inteligente para o monitoramento do desgaste da ferramenta. O sistema inicial foi composto por quatro sensores (um de força, dois de aceleração e um de corrente do motor), do algoritmo **SFS** para selecionar as características relevantes do processo e da *RNA* capaz de aprender e tomar decisões. Foi comprovado que o uso de múltiplos sensores para a detecção do desgaste não é necessário, como para o caso dos sinais obtidos da ferramenta de 25 mm na qual consegue-se monitorar o desgaste através de uma única componente de frequência do *acelerômetro X*, posicionado na direção do avanço, acompanhada dos parâmetros de usinagem.

Quanto aos picos intermediários sinalizados no gráfico da *figura 4*, estes demonstram que o algoritmo **SFS** não garante que as características de frequências selecionadas sejam as ideais, como já comprovaram **Rangwala e Dornfeld**, [7], para o processo de torneamento. Entretanto, o **SFS**, demonstra ser um

método que apresenta resultados aceitáveis dentro dos padrões da indústria metal mecânica.

A identificação de uma frequência comum para duas ferramentas (repetiu-se este experimento para fresas de topo de diâmetros distintos) relacionadas ao desgaste aumenta a confiabilidade do sistema de monitoramento proposto. Isto conduz ao caso da utilização do modelo de uma *RNA* obtida a partir dos dados de uma ferramenta para monitorar o desgaste em outra. Um modelo único de *RNA* para diferentes diâmetros de fresas apresentou um *índice de acerto* aceitável, acima dos 95%. Da mesma forma, não há garantias de repetir-se o mesmo *índice de acerto* da validação quando a *RNA* esteja monitorando um processo com valores de parâmetros de corte fora das faixas determinadas como entradas na fase de treinamento. Uma consequência disto é a tendência do sistema de monitoramento apresentar falsos alarmes de detecção do desgaste da ferramenta. Assim, para o processo de fresagem analisado, variáveis como os parâmetros de usinagem e o diâmetro da ferramenta, diferentes dos usados para os dados de treinamento, afetam sensivelmente a capacidade da *RNA* monitorar o desgaste da ferramenta durante o processo.

A regra de “quanto mais características melhor o desempenho da *RNA*” nem sempre é verdadeira. Como se constatou, 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.

Foi apresentada aqui a possibilidade da integração de sensores através da utilização de *RNA*'s. Os resultados mostram ainda a habilidade da *RNA* aprender e apresentar respostas confiáveis na identificação do desgaste da ferramenta. Através da *SFS* consegue-se extrair de padrões de sinais ruidosos a informação necessária ao monitoramento do desgaste. Neste caso dentro de uma ampla faixa de parâmetros de usinagem, conseguem-se *índices de acerto* entre 95% e 100%.

## 6 Algoritmo SFS para MATLAB

Para preparar os dados dos sinais dos sensores tomados no tempo construiu-se uma matriz que contivesse em cada uma de suas colunas o espectro de frequência de cada uma das amostras dos sinais considerados. Esta matriz foi assim constituída em suas três primeiras linhas pelas velocidades de giro, velocidade de avanço e profundidade de corte. As linhas subsequentes são compostas pelos espectros de frequências de cada uma das amostras, sendo a última linha da matriz deixada para indicar o estado da ferramenta no momento da amostragem, 1 e -1, nova ou desgastada, respectivamente.

A função criada para o MATLAB foi a FFT2SFS, tendo como entrada a matriz descrita acima e o número de características. Como saída obtém-se as características relevantes ao fenômeno que se está analisando, neste caso relativos a mudança nas condições de corte da ferramenta.

No ANEXO A apresenta-se o algoritmo preparado para o MATLAB. Neste algoritmo constroem-se duas matrizes com as amplitudes de cada uma das frequências, uma para a ferramenta nova e outra para a ferramenta desgastada. Estas duas matrizes já estão definindo as duas classes de dados que se analisa e que serão processados segundo se descreveu na seção 1.

Desta forma para cada conjunto de dados se calcula as matrizes de covariância das intra-classes e de covariância das inter-classes. Os valores destas matrizes são desta forma substituídos na equação (1) para o cálculo de  $J$ . Os valores calculados de  $J$  são armazenados, comparados com novos valores calculados, e quando for o caso de encontrar-se um novo máximo de  $J$ , adicionar a característica correspondente a este valor à lista de saída das que melhor definem o fenômeno de desgaste da ferramenta de corte.

### Anexo A: Algoritmo FFT2SFS

```
%Entrada da matriz de frequências, freqmatrix, e parâmetros de
%usagem para os vetores de medida que comporão a matriz de
%medidas.
Function saida = fft2sfs(arq_de arquivos)
Arq = arq_de arquivos;
(.....)
%ESCOLHA DAS FEATURES :
%Matrizes das medias das amplitudes de cada uma
%das frequências :
%(1) Para a ferramenta nova:
for i=1 :(size(freq_matrix,1)),
Novo_valor=sum(freq_matrix(i,2:(size(freq_matrix,2)-2)/2+...;
1))/(size(freq_matrix,2)- 2)/2); MedNova =[MedNova; Novo_valor];
end;
%(2) Para a ferramenta desgastada:
for i=1 :(size(freq_matrix,1)),
Desg_valor = sum(freq_matrix(i,((size(freq_matrix,2)-...;
2)/2)+2:size(freq_matrix,2))/(size(freq_matrix,2)-2)/2));
MedDesg = [MedDesg; Desg_valor];
end;
% Para um mesmo número de amostras de novas e desgastadas:
Mall = (MedNova + MedDesg)./2;
%% Determinação das características :
%Nfeat é o número de características que se deseja determinar:
%PREPARAÇÃO DAS MATRIZES PARA O CÁLCULO DAS
%MATRIZES DE COVARIÂNCIA
Nfeat=36; %O Número de features
freq_matrix(3:96,2:size(freq_matrix,2));
X=freq_matrix;
Xfeature= [] ;
Matriz das Médias;
Med_Matrix=[MedNova MedDesg M all];
for feat= 1 :Nfeat, % Início da contagem das features.
Jmax=0;
for ix=1:size(X,1),
% A matriz Xteste tem em sua primeira coluna as frequências, nas
% colunas seguintes as amostras dos o respectivo s ensaio s, os dois
% vetores das nova e desgastada) e o vetor da média geral:
Xteste=[X(ix, 1 : size(X,2)) Med_Matrix(ix,:)];
W1=[];W2=[]; M1_X2=[]; M2_X2=[]; Xteste=[Xfeature;Xteste] ;
for isubt=1 :size(Xteste,1),
```

```
M1_X=[]; M2_X=[];
for jsbt=2:(size(X)teste,2)-(4)-((size(Xteste,2)-5)i2)),
M1 X = [M1 X (Xteste(isubt,jsbt) - Xteste(isubt,size(Xteste,2)-2))];
M2-X = [M2-X (Xteste(isubt,jsbt)+((size(Xteste,2)-5)i2)) -...;
Xteste(isubt,size(Xteste,2)- 1)]]; end;% do for "jsbt"
M1 X2=[M1 X2; M1 X];M2-X2=[M2-X2; M2-X];
end;% do for "isubt"
W1=sum((M1 X2*M1_X2')).i((size(Xteste,2)-5)/2);
W2=sum((M2-X2*M2-X2')).i((size(Xteste,2)-5)/2);
% Matriz de covariância das intra-classes
Sw=(W1+W2)/2;
%Matriz de covariância das Inter-classes
Sb = sum((Xteste(:,size(Xteste,2)-2)-Xteste(:,size(Xteste,2)))' * ...;
(Xteste(:,size(Xteste,2)-2)-Xteste(:,size(Xteste,2))))'/2 + sum(...;
(Xteste(:,size(Xteste,2)- 1)-Xteste(:,size(Xteste,2)))' * ...;
(Xteste(:,size(Xteste,2)- 1)-Xteste(:,size(Xteste,2))))'/2);
%TESTE DE J:
J = trace(Sb)/trace(Sw);
if J>Jmax,
Jmax=J;Xmax=X(ix,1:size(X,2));imax=ix;
Med_Max=Med_Matrix(ix,:);end;
end; %o do for "ix"
Jfeat = [Jfeat; Jmax];
% Guardando o valor da função otimizada.
Xfeature = [Xfeature; Xmax Med_Max];
Xfeature(:, 1 )
%Carregando as features: A próxima matriz a ser analisada não poderá
conter X escolhido anteriormente. Recarregar a matriz :
for jcont= 1 :size(X, 1 ),
if jcont~=imax,
X2=[X2; X(jcont,:)];
Med_Matrix2=[Med_Matrix2;Med Matrix(jcont,:); end;
end; %o do "for" jcont
X=X2;X2=[]; clear X Med Matrix; Med_Matrix=Med ...;
Matrix2;Med_Matrix2=[];
end; %% % DA CONTAGEM DAS FEATURES.
save c :\temp\sfsmatx Xfeature Jfeat;
save Xfeature Jfeat;
end.
```

### Referências

- [1] M.T. Dos Santos. Estudo do Desgaste de Fresas de Topo Baseado no Emprego de Sensores. Tese de doutorado apresentada a EPUSP / Dept. de Engenharia Mecânica
- [2] A. R. Almeida e M.T. dos Santos. Neural Network-Based Tool Wear Monitoring In Milling Process Via Linear Predictive Coding. IFSA 97, Praga, 1997.
- [3] P.A. Devijver e J. Kittler. Pattern Recognition – A Statistical Approach. Prentice Hall, New Jersey, 1959.
- [4] A. Whitney, A Direct Method of Nonparametric Measurement Selection. IEEE Trans. On Computers, 20, pág. 1100-1103, 1971.
- [5] S. HAYKIN. Neural Networks. A Comprehensive Foundation. Macmillan College Publishing Company, New York, 1994.
- [6] D.A. Dornfeld. Neural Network Sensor Fusion for Tool Condition Monitoring. Annals of the CIRP, Vol. 39/1, pág. 101-105, 1990.
- [7] S. Rangwala e D.A. Dornfeld. Integration of Sensors via Neural Networks for Detection of Tool Wear Stress. Proc. Symposium on Integrated and Intelligent Manufacturing Analysis and Synthesis, ASME, New York, pág. 109-120, 1987.