



APLICAÇÃO DE UM ARRANJO FATORIAL COMPLETO AO PROJETO DOS PARÂMETROS DE UMA REDE NEURAL ARTIFICIAL RBF PARA PREDIÇÃO DA RUGOSIDADE EM PROCESSO DE TORNEAMENTO

Fabício José Pontes (UNIFEI)

fpontes@embraer.com.br

João Roberto Ferreira (UNIFEI)

jorofe@unifei.edu.br

Anderson Paulo de Paiva (UNIFEI)

andersonppaiva@yahoo.com.br

Pedro Paulo Balestrassi (UNIFEI)

pedro_brazil@me.utexas.edu

Este trabalho apresenta um estudo sobre a aplicação de um arranjo fatorial completo como ferramenta para o projeto dos parâmetros de uma rede neural RBF para predição da rugosidade da peça no torneamento de um aço SAE/ABNT 52100 - 55 HRC. Os fatores investigados no experimento são o número de unidades radiais, o algoritmo para seleção dos centros das funções radiais e o algoritmo de seleção do parâmetro de largura daquela função. Para o treinamento das redes foram utilizados dados gerados a partir de um modelo de regressão obtido e validado em um experimento de usinagem planejado segundo a Metodologia de Superfície de Resposta. A análise dos resultados sugere que a rede RBF é capaz de prever a resposta com bom desempenho.

Palavras-chaves: Fatoriais Completos, Redes Neurais, Torneamento, Aço ABNT 52100 (55 HRC).

1. Introdução

A qualidade da superfície da peça é um dos mais importantes requisitos do consumidor nos processos de usinagem. O principal indicador de tal requisito, segundo Özel e Karpat (2005), é a rugosidade da peça. A rugosidade é uma medida da qualidade tecnológica de um produto e um fator que muito influencia no custo de manufatura. Vários modelos teóricos têm sido propostos para a predição da rugosidade. Tais modelos não são exatos e se aplicam, em sua maioria, somente a uma faixa limitada de condições de corte. Segundo Diniz et al. (2005), os critérios utilizados no chão de fábrica para troca de ferramentas são conservadores, levando à troca de ferramentas bem antes do ponto em que as mesmas começam a gerar rugosidade acima do especificado. Benardos e Vosniakos (2002) afirmam que há necessidade, por parte da indústria, de ferramentas que permitam estimar a rugosidade antes da usinagem da peça, e que sejam, ao mesmo tempo, facilmente utilizáveis em ambientes de chão de fábrica.

Um estudo de Benardos e Vosniakos (2003) descreve as principais estratégias que vêm sendo utilizadas na busca pela melhoria nos processos de predição da rugosidade em processos de usinagem. Observa-se que diversos autores têm obtido bons resultados na utilização de redes neurais artificiais na tarefa de predição.

O objetivo deste trabalho é realizar um estudo exploratório do desempenho de redes neurais artificiais de arquitetura RBF (função de base radial) na predição da rugosidade média (R_a) no torneamento do aço SAE/ABNT 52100 com ferramenta de cerâmica mista, utilizando como entradas da rede os parâmetros de corte. Poucos estudos foram encontrados na literatura utilizando-se especificamente RBFs para tarefas de predição em processos de usinagem. Pontes et al. (2006) utilizaram um arranjo ortogonal de Taguchi como auxílio ao projeto de redes RBF para predição da vida da ferramenta. Alajmi, Oraby e Esat (2005) compararam algumas arquiteturas de redes neurais, RBF entre elas, na predição da vida da ferramenta. Em Sonar et al (2006) encontra-se um estudo que aplica redes RBF à predição da rugosidade da peça baseada nos parâmetros de corte.

Este trabalho fará uso de arranjos fatoriais completos como auxílio para a determinação da configuração das redes neurais. Tais arranjos constituem uma das técnicas da metodologia de projeto de experimentos (DOE). Ao final do experimento será escolhida a configuração que minimize o erro na predição da rugosidade. É esperado que as redes RBF apresentem bom desempenho na tarefa proposta.

2. Rugosidade média (R_a)

O termo rugosidade superficial se refere a desvios da superfície nominal de terceira até sexta ordem, segundo Benardos e Vosniakos (2003). Desvios de diferentes ordens se sobrepõem para formar o perfil de rugosidade da peça (BENARDOS E VOSNIAKOS, 2002).

A rugosidade superficial é caracterizada pela forma como é feita sua medição. No Brasil adota-se o sistema da “Linha Média” (M). Este é o sistema mais utilizado em todo o mundo. No sistema “M” todas as grandezas de medição são definidas a partir de uma linha paralela à direção geral do perfil, no comprimento de amostragem, seguindo uma linha que é a média entre os picos e reentrâncias de irregularidades.

O critério de medição da rugosidade adotado neste trabalho é o de profundidade de rugosidade. A grandeza medida é a rugosidade média de superfície (R_a). Esta é definida como o valor médio aritmético de todos os desvios do perfil em relação a uma linha média em um

dado comprimento de amostragem. Para medições discretas, a rugosidade superficial é definida pela equação 1 (ISO 4287/1, 1997).

$$R_a = \frac{1}{n} \sum_{i=1}^n |y_i| \quad (1)$$

na qual R_a é a rugosidade média de superfície, n é o número de amostras em um dado comprimento de amostragem L , e y_i são os valores absolutos das ordenadas do perfil efetivo (medido) em relação à linha média do comprimento de amostragem.

Ainda que não haja um modelo teórico único que torne possível a predição da rugosidade, a literatura aponta no sentido de que os parâmetros de corte são determinantes na predição. Cus e Zuperl (2006) e Fang e Safi-Jahanshahi (1997), sugeriram modelos empíricos lineares e exponenciais para a rugosidade da peça como funções da velocidade de corte (Vc), avanço (f) e profundidade de usinagem (ap). Tal modelo é mostrado na equação 2.

$$R_a = c_o (Vc^{c1} f^{c2} ap^{c3}) \quad (2)$$

Na equação 2, $c0$, $c1$, $c2$ e $c3$ são constantes específicas de uma dada combinação de material da peça e a ferramenta utilizada na usinagem.

3. Redes neurais

Segundo Haykin(1994), uma rede neural “é um processador paralelo massivamente distribuído que possui uma propensão natural a armazenar conhecimento experiencial e torná-lo disponível para uso”. Na definição de Braga et al.(2000), Redes Neurais Artificiais são sistemas paralelos distribuídos compostos por unidades de processamento simples (chamadas de nós ou neurônios), que calculam determinadas funções matemáticas, em geral não-lineares, correspondendo a uma forma de computação não-algorítmica. Em uma rede neural, o conhecimento sobre um determinado problema é armazenado sob a forma dos pesos nas sinapses que interconectam os neurônios nas camadas de rede.

O desempenho de uma rede neural em uma determinada aplicação depende de fatores ligados ao projeto da mesma e estes são geralmente determinados por métodos heurísticos, segundo Haykin (1994). A aplicação de redes neurais na resolução de um dado problema envolve também uma fase de aprendizagem e uma fase de testes.

Por aprendizagem entende-se o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando. Nota-se dois paradigmas principais para tal fase: aprendizado supervisionado e aprendizado não supervisionado. Dentro de cada paradigma, existem diferentes algoritmos de treinamento, que são definidos como as regras para os ajustes realizados dos pesos entre as sinapses.

Haykin (1994) recomenda a utilização de dois conjuntos distintos de dados durante o projeto de uma rede neural: um conjunto para treinamento e outro para teste da rede. O conjunto de teste não entra no treinamento da rede e é usado após o mesmo, durante a fase de testes, como meio de estimar-se de maneira independente o desempenho da mesma. Recomenda ainda que a ordem na qual exemplos são apresentados à rede durante o treinamento seja aleatória.

3.1 Redes RBF

Redes RBF (*Radial Base Function*) são um modelo de redes neurais multicamada no qual a ativação de uma unidade da camada intermediária é função da distância entre seus vetores de

entrada e de peso, ou seja, uma função de base radial (Bishop, 1995). Aos neurônios constituintes de uma rede do tipo RBF dá-se o nome de unidades radiais. A função radial em uso em RBFs é, geralmente, uma função gaussiana, do tipo mostrado na equação 3.

$$\phi(\mu) = -\exp\left(-\frac{\|x - \mu\|^2}{2\sigma^2}\right) \quad (3)$$

onde x corresponde ao vetor de entrada da unidade, μ representa o centro da função radial e σ representa a largura da mesma, isto é, um parâmetro que controla quão intenso é o decaimento do valor de saída da função de ativação à medida que varia a distância ao centro. Em uma rede RBF com k unidades radiais na camada intermediária e uma única saída, esta é dada pela equação 4 (BISHOP, 1995).

$$y = \sum_{i=1}^k w_i \phi(\|x - \mu\|^2) + w_0 \quad (4)$$

onde x e μ são definidos como na equação 3, k é o número de unidades radiais presentes na camada intermediária, ϕ representa a função de ativação das unidades radiais, como, por exemplo, a função definida em pela equação 3, w_i representa os pesos pelos quais a saída de uma unidade radial é multiplicada na camada de saída e w_0 um fator constante.

O treinamento de redes RBFs envolve duas fases. Na primeira fase, os parâmetros da função radial utilizada (os centros e a largura) são determinados por métodos não supervisionados. Durante a segunda fase é realizado o ajuste dos pesos dos neurônios de saída, correspondendo a um problema linear, de processamento mais simples (Haykin, 1994).

Os dois métodos usualmente utilizados para seleção dos centros são a Sub-amostragem (*Sub-sampling*) e o algoritmo K-Médias (*K-Means*). Após a seleção dos centros, deve-se determinar o fator de largura da função. Os algoritmos mais utilizados para essa operação são o Isotrópico e o algoritmo dos K-Mais Próximos (*K-Nearest*). Após essa primeira fase, o passo seguinte corresponde à otimização da camada de saída, que pode ser feita empregando-se uma técnica padrão para otimização linear: a decomposição por valor singular (HAYKIN, 1994)(BISHOP, 1995).

Bishop (1995) afirma que tal modelo de rede é apropriado para desempenhar diversas tarefas, dentre as quais se inclui a aproximação de funções. Uma camada intermediária, segundo o mesmo autor, é o suficiente para a aproximação de qualquer função.

4. Fatoriais completos

Um planejamento fatorial é completo quando todas as possíveis combinações entre os fatores envolvidos são experimentadas (BOX, HUNTER E HUNTER, 1978). Em um experimento planejado segundo a técnica do fatorial completo cada fator é testado e re-testado um igual número de vezes em cada um dos seus níveis, os quais são escolhidos de maneira apropriada dentro de sua amplitude normal de variação. Arranjos fatoriais completos cobrem todo o espaço experimental e correspondem ao arranjo experimental mais comum (PAIVA, 2006). Tal técnica permite avaliar não somente os efeitos principais dos fatores como também os efeitos de interação entre os mesmos.

O número de experimentos é igual ao número de níveis experimentais elevado ao número de fatores. Para experimentos fatoriais em dois níveis, o número de corridas experimentais (N) para se avaliar os k fatores é dado por $N = 2^k$. Logo, enquanto o número de fatores cresce linearmente, o número de corridas cresce exponencialmente.

Arranjos fatoriais completos podem ser gerados para qualquer quantidade de fatores e os

níveis de cada fator se alternam nas colunas, segundo uma mesma ordem. Para a primeira coluna, os níveis se alteram a cada (2^0) experimento; para a segunda coluna, os níveis se alteram a cada (2^1) experimentos; para a terceira coluna, os níveis se alteram a cada (2^2) experimentos e assim por diante. O procedimento se repete para tantas colunas quantas forem os k fatores, até a k -ésima coluna.

5. Geração dos casos de treinamento

Para geração dos casos utilizados no experimento fez-se uso de um modelo de regressão múltipla obtido por Pereira (2006) em um experimento de torneamento do aço SAE/ABNT 52100 – 55 HRC com ferramentas com insertos de cerâmica mista ($Al_2O_3 + TiC$), classe Sandvik GC 6050, recoberta com TiN, com geometria ISO CNGA 120408 S01525. Tal experimento foi planejado e executado segundo a Metodologia da Superfície de Resposta combinada com a técnica do fatorial completo.

O modelo resultante foi validado estatisticamente por meio de testes de análise de variância (ANOVA) e apresenta um alto nível de ajuste, com $R^2 \text{ adj} = 89,1\%$. A equação de regressão característica do modelo para a Rugosidade Média (R_a) da peça é apresentada na equação 5, em unidades codificadas (PEREIRA, 2006).

$$y = 0,357 + 0,016Vc + 0,134f - 0,008ap + 0,021Vc^2 + 0,066f^2 + 0,001ap^2 - 0,026Vc.f + 0,050Vc.ap - 0,017f.ap \quad (5)$$

Para este trabalho, gerou-se um arquivo com 150 conjuntos de dados (Vc, fn, ap, y) a partir da equação 5, sendo y o valor correspondente à Rugosidade Média da superfície usinada, em μm , prevista segundo o modelo utilizado, Vc é a velocidade de corte em m/min, fn é o avanço, dado em mm/rotação, e ap é a profundidade de corte, medida em mm. Dentre os exemplos gerados, 30 foram utilizados como conjunto de treinamento e 120 foram utilizados como conjunto de testes. Optou-se por utilizar um tamanho reduzido do conjunto de treinamento com o objetivo de averiguar a capacidade da rede neural de apresentar bons resultados com poucos exemplos. Isso é necessário para que a RBF possa constituir-se em opção viável para aplicação em experimentos reais, os quais tipicamente possuem custo elevado e não podem contar com número elevado de repetições.

6. Planejamento experimental

O arranjo fatorial utilizado para cada experimento foi um arranjo fatorial com três fatores distribuídos em dois níveis, totalizando oito corridas em cada experimento. Os níveis de cada fator são detalhados no quadro 1.

Nível do fator	-1	+1
Algoritmo para determinação do parâmetro de largura da função radial	Algoritmo Isotrópico - Fator de escala = 10	K-Mais Próximos K=10
Número de unidades radiais	15	23
Algoritmo para determinação de centros da função radial	Sub-amostragem	K-Médias

Quadro 1 – Níveis dos fatores utilizados nos experimentos definitivos com fatorial completo

Segundo Sick (2002), a falta de repetições para cada combinação de níveis é um dos fatores que impede uma eficaz análise estatística que sustente as conclusões dos trabalhos

envolvendo redes neurais na tarefa de predição. Para evitar-se tal problema neste trabalho, cada configuração foi inicializada, treinada e testada independentemente por sessenta vezes. O experimento foi conduzido com a utilização do software estatístico Statistica®.

A grandeza de saída utilizada como medida para comparação da influência dos diferentes fatores foi a Razão de Desvios Padrão da fase de testes da rede. Em um problema de regressão, a Razão de Desvios Padrão é definida como sendo a relação entre o desvio-padrão dos resíduos da predição pelo pelo desvio padrão dos dados experimentalmente obtidos. Assim, quanto menor o valor da Razão de Desvios Padrão, melhor a capacidade de predição da rede neural. A Razão de Desvios Padrão corresponde a 1 menos a variância explicada pelo modelo.

7. Análise dos resultados

Os experimentos com a utilização de fatoriais completos permitiram a determinação dos níveis dos fatores que mais influem na resposta Razão de Desvios Padrão. Fez-se a análise dos efeitos principais e de interação entre os fatores, como mostrado nas figuras 1 e 2.

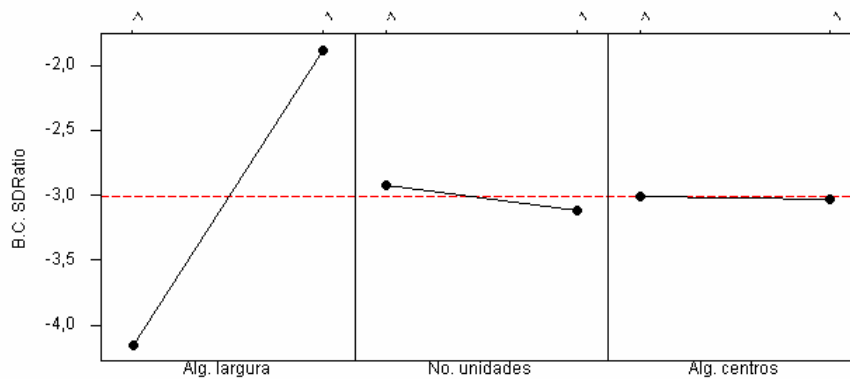


Figura 1 – Efeitos principais para resposta Razão de Desvios Padrão. Fonte: Minitab 13.0®

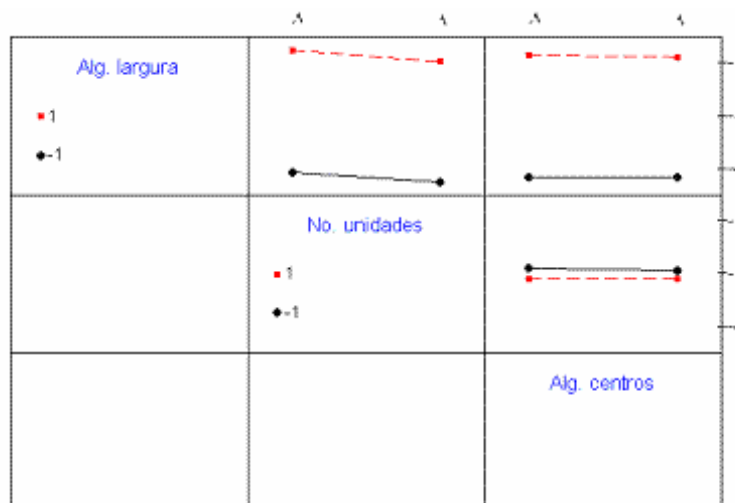


Figura 2 – Efeitos de interação para resposta Razão de Desvios Padrão. Fonte: Minitab 13.0®

De acordo com vários autores (Montgomery, 2001; Box, Hunter & Hunter, 1978; Noordin et al., 2004), em projetos de experimentos deve-se realizar a análise dos resíduos das respostas. Segundo Montgomery (2001), os resíduos devem ser normais, independentes (não-correlacionados) e identicamente distribuídos. Assim sendo, foram analisados os resíduos da

predição da Rugosidade Média, por meio do teste de Anderson-Darling, ao nível de significância de 0,05. O teste apresentou um valor P igual a 0,215, indicando que não há evidência, ao nível adotado, de que os resíduos não sigam a distribuição normal. Uma vez que os resíduos foram normalizados, foi possível utilizar os resultados da análise de variância, cujos resultados são mostrados nas tabelas 1 e 2.

A análise das tabelas 1 e 2 permite concluir, ao nível de significância adotado de 0,05, que somente o algoritmo para determinação da largura da função radial e o número de unidades radiais são significativos para a resposta, o que se infere pelo valor P observado nas linhas dedicadas aos efeitos principais. Não se observa interação significativa, o que se infere pelo valor P observado nas linhas dedicadas aos efeitos de interação, superior ao nível de significância adotado.

Termo	Efeito	Coefficiente	Desvio Padrão do Coeficiente	T	Valor P
Constante		-3,016	0,01497	-201,38	0,000
Alg. det. parâmetro largura	2,286	1,143	0,01497	76,33	0,000
No. unidades radiais	-0,196	-0,098	0,01497	-6,55	0,000
Alg. det. centros	-0,023	-0,011	0,01497	-0,76	0,451
Alg. det. parâmetro largura *No. unidades radiais	-0,017	-0,009	0,01497	-0,58	0,562
Alg. det. parâmetro largura *Alg. det. centros	-0,015	-0,007	0,01497	-0,50	0,622
No. unidades radiais *Alg. det. centros	0,024	0,012	0,01497	0,80	0,424
Alg. det. parâmetro largura *No. unidades radiais *Alg. det. centros	-0,022	-0,011	0,01497	-0,75	0,456

Tabela 1 - Efeitos estimados dos coeficientes, experimento para Rugosidade Média com arranjos fatoriais completos utilizando 30 casos de treinamento. Fonte: Minitab 13.0®

Fonte	Graus de liberdade	SQ Seq.	SQ Ajustada	MQ Ajustada	F	Valor P
Efeitos Principais	3	105,305	105,305	35,1017	2E+03	0,000
Interações de Segunda Ordem	3	0,022	0,022	0,0074	0,41	0,746
Interações de Terceira Ordem	1	0,010	0,010	0,0101	0,56	0,456
Erro Residual	72	1,292	1,292	0,0179		
Erro Puro	72	1,292	1,292	0,0179		
Total	79	106,629				

Tabela 2 - Análise de variância, experimento para Rugosidade Média com arranjos fatoriais completos utilizando 30 casos de treinamento. Fonte: Minitab 13.0®

O diagrama de Pareto obtido do experimento é mostrado na figura 3. O valor de alfa adotado foi de 0,05. Sua análise permite obter uma impressão da importância relativa de cada efeito. Nota-se a maior importância do fator ‘algoritmo para determinação do parâmetro de largura da função radial’ para o desempenho da rede, quando se compara seu efeito ao dos demais fatores.




Figura 3 – Diagrama de Pareto ($\alpha=0,05$), experimento para Rugosidade Média com arranjos fatoriais completos utilizando 30 casos de treinamento. Fonte: Minitab 13.0®

A análise dos resultados levou à determinação da configuração que apresenta melhores resultados na tarefa de predição da Rugosidade Média, mostrada no quadro 2.

Número de casos de treinamento	Algoritmo para determinação parâmetro de largura da função radial	Número de unidades radiais	Algoritmo para determinação de centros da função radial
30	Alg. Isotrópico - Fator de escala = 10	23	Sub-amostragem
30 (alternativa)	Alg. Isotrópico - Fator de escala = 10	23	Alg. K-Médias

Quadro 2 – Configurações apontadas como as melhores para predição da Rugosidade Média (R_a), para cada experimento envolvendo arranjos fatoriais completos

O algoritmo isotrópico com fator de escala igual a 10 apresentou os melhores resultados. Em relação ao número de unidades radiais na camada oculta, os experimentos realizados indicaram melhores resultados com um número de 23. Isto corresponde a uma relação de aproximadamente $\frac{3}{4}$ entre o número de unidades e o número de casos de treinamento. Ao inspecionar-se a tabela dos efeitos estimados dos coeficientes (tabela 1), observa-se que o fator ‘algoritmo para determinação dos centros’ não é significativo ao nível de 0,05. Desta forma, tanto o método da sub-amostragem quanto o algoritmo das K-Médias podem ser utilizados indistintamente. Os valores médios da resposta Razão de Desvios Padrão, do desvio padrão e do erro padrão da média, para a melhor configuração de rede obtida são mostrados na tabela 3.

Número de casos no conjunto de treinamento	Valor médio da resposta Razão de Desvios Padrão para a configuração proposta	Desvio Padrão para a resposta Razão de Desvios Padrão	Erro-padrão da média
30	0,014064	0,002929	0,208262

Tabela 3 – Valores médios da resposta Razão de Desvios Padrão, desvios padrão e erros-padrão da média para a melhor rede obtida para predição da Rugosidade

Sendo este experimento exploratório, os resultados não permitem afirmar que a configuração de rede proposta seja a que apresenta desempenho ótimo para as condições de teste. Nota-se, porém, que o valor da variável de saída é bastante reduzido, o que sugere que redes RBF

podem apresentar bom desempenho na predição da rugosidade, para os níveis estudados.

8. Conclusões

No presente trabalho realizou-se um estudo exploratório sobre a aplicabilidade de redes RBF à tarefa de predição da rugosidade da peça em processo de torneamento, treinadas pelos parâmetros de corte do processo de usinagem. A Razão de Desvios Padrão foi utilizada como medida de desempenho na predição. Foram apresentados os resultados da análise da utilização de um arranjo fatorial completo para o projeto dos parâmetros de redes neurais RBF para uso na aplicação proposta. Os resultados sugerem que as redes RBF podem apresentar bom desempenho na predição da rugosidade da peça. O valor observado durante os testes para a variável de saída foi de 0,014064, o que é um valor bastante reduzido.

As conclusões obtidas neste experimento não devem ser extrapoladas para outros tipos de redes neurais nem tampouco para dados referentes a outros tipos de operações de usinagem, outros materiais ou ferramentas.

Referências

- ALAJMI, M. S.; ORABY, S. E. & ESAT, I. I.** *Neural network models on the prediction of tool wear in turning process: a comparison study.* Proceedings of the IASTED Conference Artificial Intelligence and Applications, Innsbruck, Austria, p.301-309, 2005.
- BENARDOS, P. G. & VOSNIAKOS, G. C.** *Prediction of surface roughness in CNC in machining: a review.* International Journal of Machine Tools & Manufacture, V43, p.833-844, 2003.
- BENARDOS, P. G. & VOSNIAKOS, G. C.** *Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments.* Robotics and Computer Integrated Manufacturing, V18, p.343-354, 2002.
- BISHOP, C. M.** *Neural Networks for Pattern Recognition.* New York: Oxford University Press Inc., 1995, 482p.
- BOX, G. E. P.; HUNTER, W. G. & HUNTER, J. S.** *Statistics for Experimenters.* New York: John Wiley & Sons, 1978.
- BRAGA, A. P.; CARVALHO, A. P. L. F. & LUDERMIR, T. B.** *Redes Neurais Artificiais: Teoria e Aplicações.* Rio de Janeiro: LTC Livros Técnicos Editora S. A., 2000, 262p.
- CUS, F. & ZUPERL, U.** *Approach to optimization of cutting conditions by using artificial neural networks.* Journal of Materials Processing Technology, V173(3), p.281-290, 2006.
- FANG, X. D. & SAFI-JAHANSHAH.** *A new algorithm for developing a reference model for predicting surface roughness in finishing machining of steels.* International Journal of Production Research, V35 (1), p.179-197, 1997.
- HAYKIN, S.** *Neural Networks - A comprehensive foundation.* New York: Mcmillan Publishing Company, 1994, 696p.
- ISO 4287:1997/Cor 2:2005.** *Geometrical Product Specifications (GPS) - Surface texture: Profile method - Terms, definitions and surface texture parameters,* International Organization for Standardization, 2005.
- MONTGOMERY, D. C.** *Design and Analysis of Experiments,* John Wiley & Sons, 5^a ed., 2001, 699p.
- NOORDIN, M. Y.; VENKATESH, V. C.; SHARIF, S.; ELTING, S. & ABDULLAH, A.** *Application of response surface methodology in describing the performance of coated carbide tools when turning AISI 1045 steel.* Journal of Materials Processing Technology, V145., 2004.
- ÖZEL, T. & KARPAT, Y.** *Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks.* International Journal of Machine Tools and Manufacture, V45, p.467-479, 2005.

PAIVA, A. P. *Metodologia de Superfície de Resposta Multivariada – Uma proposta de otimização para processos de manufatura com múltiplas respostas correlacionadas.* 2006. 279p. Tese de Doutorado – UNIFEI – Universidade Federal de Itajubá.

PEREIRA, J. C. C. *Determinação de modelos de Vida de ferramenta e rugosidade no torneamento do aço ABNT 52100 Endurecido utilizando Metodologia de Superfície de Resposta (DOE).* 2006. Dissertação de Mestrado - UNIFEI - Universidade Federal de Itajubá. 140p.

PONTES, F. J.; FERREIRA, J. R. & PAIVA, A. P. *Aplicação de um arranjo ortogonal de Taguchi ao projeto dos parâmetros de uma Rede Neural Artificial RBF para previsão da vida de ferramentas em processo de torneamento.* Anais do XXVI ENEGEP-Encontro Nacional de Enga. de Produção, 09-11 de Outubro de 2006, vol. 1, Fortaleza-CE, p.1-8.

SONAR, D. K.; DIXIT, U. S. & OJHA, D. K. *The application of a radial basis function neural network for predicting the surface roughness in a turning process.* The International Journal of Advanced Manufacture Technology (2006) 27:661-666.

SICK, B. *On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research.* Mechanical Systems and Signal Processing, V16, no. 4, July 2002, p.487-546, 2002.