

PROJETO DE EXPERIMENTOS APLICADO AO PROJETO DE REDES NEURAIIS RBF PARA PREDIÇÃO DA RUGOSIDADE MÉDIA (R_a) EM PROCESSO DE TORNEAMENTO DE AÇO SAE/ABNT 52100

Fabrizio José Pontes, fabriziojosepontes@uol.com.br¹

João Roberto Ferreira, jorofe@unifei.edu.br²

Anderson Paulo de Paiva, andersonppaiva@yahoo.com.br²

¹FEG-UNESP, Faculdade de Engenharia de Guaratinguetá-Universidade Estadual Paulista,

²UNIFEI, Universidade Federal de Itajubá

Resumo: Neste estudo a metodologia estatística do Projeto de Experimentos foi aplicada à determinação dos parâmetros de Redes Neurais Artificiais de Função de Base Radial (RBF) utilizadas para a predição da Rugosidade Média (R_a) no processo de torneamento do aço SAE/ABNT 52100 – 55 HRC. Os fatores investigados foram o algoritmo para a determinação do parâmetro de largura da função radial, o número de unidades radiais e o algoritmo para determinação dos centros das funções radiais. Foram realizados experimentos com conjuntos de treinamento de diferentes tamanhos com o objetivo de identificar configurações de rede com melhor desempenho para cada número de exemplos. As redes projetadas com uso da metodologia revelaram-se capazes predizer a resposta de maneira exata, precisa e economicamente viável. Foi estimada a importância relativa dos fatores de projeto sobre o desempenho das redes. Os resultados mostraram também que efeitos de interação entre fatores de projeto têm influência significativa sobre o desempenho de redes RBF na predição da rugosidade. As conclusões indicam que a metodologia de projeto de experimentos pode constituir uma abordagem sistemática para projeto de redes neurais superior à procura de configurações por tentativa e erro, ou à estratégia de variar um parâmetro por vez.

Palavras-chave: Projeto de Experimentos; Rugosidade superficial; Redes Neurais; Torneamento; aço SAE/ABNT 52100 (55 HRC).

1. INTRODUÇÃO

A qualidade da superfície da peça é um dos mais importantes requisitos do consumidor nos processos de usinagem. Segundo Basheer et al. (2008), as características das superfícies influenciam diretamente a qualidade do produto usinado, pois estão relacionadas à habilidade do material de suportar tensão, extremos de temperatura, fricção e corrosão. Um importante indicador de tal requisito é a rugosidade superficial, de acordo com Özel e Karpaz (2005).

A predição da rugosidade superficial tem atraído inúmeros esforços de pesquisa. Al-Ahmari (2007) sustenta que modelos de usinabilidade são fundamentais para a boa seleção de parâmetros de processo no planejamento de operações de manufatura. Dentre as estratégias utilizadas na busca pela melhoria nos processos de predição da rugosidade em processos de usinagem, observa-se que diversos autores têm obtido bons resultados com a utilização de redes neurais artificiais (RNAs). Apesar disso, um problema muito citado na literatura é o da otimização dos parâmetros da rede. Zhong et al. (2006) afirmam em seu trabalho que não existe solução exata para a definição do número de camadas e unidade requeridas para aplicações particulares.

Este trabalho investiga os efeitos do número de casos de treinamento sobre o desempenho de redes neurais de função de base radial (RBF) aplicadas à predição da Rugosidade Média (R_a) da peça no torneamento do SAE/ABNT 52100 – 55 HRC. Para tanto, experimentos com conjuntos de treinamento de tamanhos distintos foram realizados.

A metodologia de Projeto de Experimentos é utilizada para a determinação de configuração das redes. A técnica dos fatoriais completos foi utilizada na busca por configurações que minimizassem os erros da rede na predição da rugosidade. Os fatores experimentais considerados foram os parâmetros de configuração da rede neural: número de unidades radiais na camada oculta da rede neural, algoritmo utilizado para determinação dos hiper-centros das funções radiais e algoritmo para determinação do parâmetro de largura da função radial.

Os parâmetros de corte foram utilizados como entradas das redes. Resultados de experimentos práticos foram utilizados para a geração dos casos de treinamento e de avaliação do desempenho das RNAs na tarefa de predição da rugosidade.

Efeitos de interação entre fatores de projeto foram avaliados. Os resultados do estudo foram expressos na forma de parâmetros de configuração para as redes que apresentaram melhor desempenho na predição, para cada tamanho de conjunto de treinamento.

2. REVISÃO TEÓRICA

2.1. Rugosidade superficial

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, como afirmam Benardos e Vosniakos (2002).

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 Eq. 1 (ISO 4287/1, 2005).

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

Na Eq. 1, 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. Oktem et al. (2006) afirmam que a rugosidade média (R_a) é o parâmetro mais utilizado para a avaliação da rugosidade.

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 (Shaw, 2004; Trent e Wright, 2000). Cus e Zuperl (2006) sugeriram modelos empíricos lineares e exponenciais para a rugosidade da peça como função da velocidade de corte (V_c), avanço (f) e profundidade de usinagem (ap).

2.2. Redes Neurais de Função de Base Radial (RBF)

Redes neurais de Função de Base Radial, ou RBFs, correspondem a uma arquitetura de redes neurais multi-camada na 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. O conceito de redes RBF foi introduzido pelo trabalho de Broomhead e Lowe (1988). 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 Eq. 2 (Bishop, 1995).

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

Na Eq. 2, 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 Eq. 3 (Bishop, 1995).

$$y = \sum_{i=1}^k w_i \phi(\|x - \mu\|^2) + w_0 \quad (3)$$

Na Eq. 3, x e μ são definidos como na Eq. 2, k é o número de unidades radiais presentes na camada intermediária, ϕ representa uma função de ativação das unidades radiais, como, por exemplo, a função definida em pela Eq. 2, w_i representa os pesos pelos quais o resultado do processamento de uma unidade radial é multiplicado na camada de saída e w_0 um fator constante.

Segundo Haykin (1998), 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, que corresponde a um problema linear, de processamento mais simples.

Os dois métodos usualmente utilizados para seleção dos centros são a Sub-amostragem e o algoritmo K-Médias. 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. 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, 1998; 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.

2.3. Redes neurais aplicadas à predição em processos de usinagem

Muitos são os trabalhos encontrados na literatura que aplicam redes neurais a tarefas de predição em processos de usinagem (Erzurumlu e Oktem, 2007; Çaydas e Hasçalik, 2007; Bağci e Işık, 2006). Redes de arquitetura perceptron multi-camada (MLP) correspondem à arquitetura mais empregada. Parâmetros de corte tais como velocidade de corte, avanço e profundidade de corte são utilizados como entradas para a rede neural, como se observa em diversos trabalhos (Bağci e Işık, 2006; Oktem et al., 2006; Choudury e Bartarya, 2003).

Poucos trabalhos fazem uso de redes neurais de função de base radial (RBF) para a predição em processos de usinagem. Em Sonar et al. (2006), redes RBF são aplicadas à predição da rugosidade superficial, sendo treinadas com parâmetros de corte do processo. El-Mounayri et al. (2005) aplicam redes RBF à predição de forças de corte. Os resultados daquele trabalho revelam que redes RBF obtiveram alto nível de exatidão na tarefa proposta. Além disso, é enfatizada a rapidez do treinamento da rede. Cus e Zuperl (2006) compararam o desempenho de redes MLP e RBF aplicadas à predição da rugosidade superficial em processo de torneamento. São mostradas evidências de que redes RBF são confiáveis e de que seu treinamento é rápido na comparação com o requerido para o treinamento de MLPs. Não se encontra porém, naqueles trabalhos, esforço no sentido de otimizar o desempenho da rede por meio do ajuste de seus parâmetros de projeto.

São raros os trabalhos que utilizam métodos de otimização aplicados à configuração de redes neurais aplicadas a processos de usinagem, sendo a configuração por tentativa e erro a abordagem mais comum, segundo Sick (2002). Em relação a redes aplicadas a outros processos, observa-se que a metodologia de Taguchi é utilizada em Balestrassi et al. (2008), para otimização da configuração de redes MLP aplicadas à predição de séries temporais. Kim e Yum (2004) utilizaram a metodologia de Taguchi para o projeto dos parâmetros de uma rede MLP com o objetivo de maximizar a robustez da rede em presença de ruídos na informação de treinamento.

2.4. Fatoriais completos e análise de variância (ANOVA)

De acordo com Montgomery (2004), a metodologia de Projeto de Experimentos (DOE) consiste no uso de técnicas estatísticas capazes de gerar dados apropriados para uma análise estatística que resulte em conclusões válidas e objetivas. Consiste na execução de experimentos nos quais fatores de um processo sob análise são variados simultaneamente, com o objetivo de medir seus efeitos sobre a variável (ou variáveis) de saída de tal processo. Neste trabalho, a metodologia foi utilizada como ferramenta de projeto para redes.

Fatoriais completos correspondem a uma técnica do DOE na qual todas as possíveis combinações de níveis dos fatores experimentais são exercitadas, de modo a cobrir todo o espaço experimental. O número de corridas é igual ao número de níveis elevado ao número de fatores. Para experimentos fatoriais em dois níveis, o número total de corridas N necessárias para avaliar o efeito de k fatores é dado por $N = 2^k$.

Na metodologia DOE, o teste empregado para avaliar a significância dos efeitos das mudanças nos níveis dos fatores ou dos efeitos das interações entre níveis sobre a saída do processo é um teste de hipótese para médias. Na técnica do fatorial completo, o teste utilizado é a análise de variância, ou ANOVA (Montgomery, 2004). A estatística empregada pela ANOVA para testar a igualdade entre médias é baseada no quociente formado pela variância entre diferentes tratamentos pela variância observada entre os resultados de um tratamento (variância interna). Essa variância interna se origina das diferenças nos resultados das réplicas realizada para um dado tratamento. A variância entre tratamentos diferentes se origina das diferenças entre as médias das respostas observadas para cada tratamento e da média geral observada.

Dividindo-se a variância entre tratamentos pela variância interna, uma estatística F é obtida. A estatística F é então comparada a um valor crítico F_0 , definido pelo nível de significância que se deseja e pelo número de graus de liberdade envolvido. O resultado do teste torna possível avaliar a hipótese nula de igualdade entre os valores médios dos efeitos dos tratamentos ou dos efeitos das interações entre os níveis dos tratamentos. Se F é maior que o valor crítico F_0 , o que implica um valor P menor que o nível de significância adotado, então o efeito pode ser considerado significativo àquele nível de significância.

3. DESENVOLVIMENTO EXPERIMENTAL

3.1. Geração dos conjuntos de treinamento e caracterização das redes

A abordagem experimental utilizada consistiu na realização de uma série de experimentos planejados como o intuito de encontrar a melhor configuração de rede para a predição da rugosidade superficial. Dados para o treinamento das redes foram originados a partir dos resultados de experimentos de corte efetuados por Pereira (2006), executados com o material que é objeto deste estudo e realizados segundo a Metodologia da Superfície de Resposta. As condições de corte experimentadas naquele trabalho são apresentadas na Tab. (1). A rugosidade foi medida para cada combinação dos parâmetros e calculou-se um modelo polinomial para a resposta.

Na Tab. (2), $x_1 = \text{ISO10}$ significa Algoritmo Isotrópico com fator de escala igual a 10; $x_1 = \text{ISO1}$ significa Algoritmo Isotrópico com fator de escala igual a 1; $x_1 = \text{KN10}$ significa Algoritmo dos K-mais próximos com fator K igual a 10; $x_1 = \text{KN5}$ significa Algoritmo dos K-mais próximos com fator K igual a 5; $x_3 = \text{SS}$ significa algoritmo de sub-amostragem, e $x_3 = \text{KM}$ significa algoritmo das K-Médias.

A variável de saída escolhida como medida para avaliação do desempenho da rede é o valor médio da razão dos desvios-padrão (S. D. Ratio) obtida durante a fase de testes da rede. Esta é definida como a razão entre o desvio-padrão dos resíduos da predição e o desvio-padrão dos dados obtidos experimentalmente. É uma figura de mérito do tipo ‘quanto menor, melhor’. Quanto mais próximo de zero o valor médio de S. D. Ratio, menor o erro de predição da rede neural. S. D. Ratio corresponde a um menos a variância explicada pelo modelo preditor. Tal grandeza tem sido utilizada para avaliar o desempenho de redes neurais em aplicações de regressão, como se vê em Bolanča et al (2005) e Dobrzánski et al. (2004), e especificamente em problemas de regressão envolvendo redes RBF, como por exemplo em Bolanča et al (2007).

3.3. Execução dos Experimentos

A execução de cada arranjo experimental consistiu em configurar a rede da maneira especificada em cada uma das oito combinações experimentais, treinar e testar a rede. A fase de testes consistiu em fazer com que as redes treinadas predisssem a rugosidade para os 120 casos de teste não utilizados no treinamento. Foi possível assim obter uma estimativa independente de seu desempenho. O treinamento e os testes foram realizados com uso do pacote computacional Statistica®, versão 7.1.

Sessenta réplicas foram realizadas para cada configuração de rede testada. Isto significa que cada configuração de rede sob teste foi inicializada de maneira aleatória, treinada e testada sessenta vezes. O objetivo das repetições foi o de mitigar o risco de desvios ligados à aleatoriedade na inicialização dos pesos da rede. Os casos de treinamento foram apresentados à rede em sequência aleatória durante a fase de treinamento. Em relação às fases de pré e pós processamento, os dados foram linearmente escalonados. Os resultados obtidos foram armazenados sob o formato de arquivos produzidos pelo pacote computacional empregado, contendo a predição das redes para os casos de teste. Os resultados foram compilados e analisados para determinar a exatidão e a variabilidade das predições das redes sob teste.

4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Foram analisados os efeitos principais e os efeitos de interação entre níveis dos fatores, para cada um dos doze experimentos realizados. Os resíduos foram normalizados. As Figs. (1) e (2) mostram, a título de exemplo, os gráficos dos efeitos principais e dos efeitos de interação obtidos do experimento envolvendo um conjunto de treinamento composto por 24 exemplos.

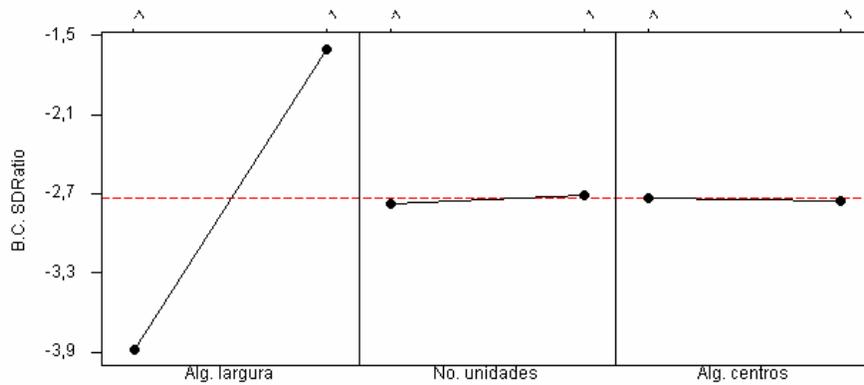


Figura 1. Efeitos principais para o experimento com 24 casos de treinamento

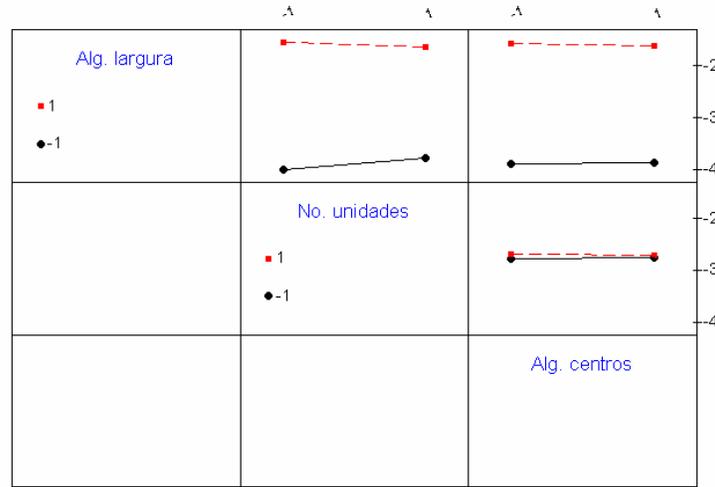


Figura 2. Efeitos de interação para o experimento com 24 casos de treinamento

Normalizados os resíduos, foi possível empregar o teste de análise de variância. Os resultados da análise permitiram determinar fatores e interações significativos para o desempenho das redes na tarefa de predição. A Tab. (3) mostra os resultados da ANOVA para a significância dos efeitos no experimento envolvendo 24 casos de treinamento. Os resultados da revelam quais efeitos têm impacto significativo sobre o desempenho das redes. Um fator foi considerado como significativo quando seu valor P se mostrou inferior ao nível de significância adotado, que foi de 0.05. Por este critério, os efeitos significativos para a predição da rugosidade superficial no experimento envolvendo 24 exemplos de treinamento são os efeitos principais dos fatores x_1 (algoritmo para o cálculo do parâmetro de largura da função radial) e x_2 (número de unidades radiais na camada oculta), assim como a interação entre os fatores x_1 e x_2 . Os resultados do teste para os doze experimentos são sumarizados na Tab. (4).

Tabela 3. Efeitos estimados dos coeficientes para experimento com 24 casos de treinamento

Fonte	Efeito	Coefficiente	Desvio-padrão coeficiente	T	Valor P
x_1	2,294	1,147	0,01257	91,28	0,000
x_2	0,068	0,034	0,01257	2,71	0,008
x_3	-0,017	-0,008	0,01257	-0,66	0,508
x_1*x_2	-0,158	-0,079	0,01257	-6,27	0,000
x_1*x_3	-0,025	-0,013	0,01257	-1,01	0,314
x_2*x_3	-0,021	-0,010	0,01257	-0,83	0,407
$x_1*x_2*x_3$	-0,013	-0,006	0,01257	-0,51	0,608

Tabela 4. Valores P para efeitos e interações, para os experimentos realizados

Fonte	Número de exemplos no conjunto de treinamento											
	12	15	24	30	48	60	120	150	240	300	400	500
x_1	0,854	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
x_2	0,000	0,000	0,008	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
x_3	0,010	0,375	0,508	0,451	0,000	0,000	0,007	0,171	0,001	0,726	0,004	0,282
x_1*x_2	0,000	0,000	0,000	0,562	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
x_1*x_3	0,003	0,000	0,314	0,622	0,002	0,000	0,000	0,059	0,201	0,474	0,000	0,009
x_2*x_3	0,004	0,494	0,407	0,424	0,108	0,526	0,011	0,678	0,675	0,674	0,000	0,094
$x_1*x_2*x_3$	0,075	0,000	0,608	0,456	0,550	0,394	0,135	0,318	0,121	0,548	0,000	0,407

A análise dos valores absolutos dos efeitos tornou possível determinar as configurações de rede que apresentam melhor resultado na tarefa de predição entre as configurações testadas, para cada tamanho do conjunto de treinamento, como se mostra na Tab. (5).

O algoritmo Isotrópico empregado com fator de escala igual a 10 apresentou os melhores resultados em todos os experimentos. Em cinco dos experimentos realizados (aqueles envolvendo 12, 15, 30, 48 e 60 casos de treinamento) os melhores resultados foram obtidos com proporções de $\frac{3}{4}$ entre número de unidades radiais na camada oculta da rede e número de casos de treinamento. Nos demais experimentos o número de unidades radiais que apresentou melhor desempenho correspondeu à proporção de $\frac{1}{2}$ entre o número de unidades radiais e número de exemplos.

Com relação ao peso relativo de cada fator no desempenho das redes, pode-se observar que o fator x_1 (algoritmo para o cálculo do parâmetro de largura da função radial) foi o mais importante em dez dos experimentos. A única exceção foram os experimentos envolvendo 12 e 15 casos. Os efeitos do fator x_1 se tornaram dominantes nos experimentos envolvendo número de casos de treinamento igual ou superior a 24. O fator adquire peso progressivamente maior à medida que o número de exemplos disponíveis para treinamento aumenta.

Tabela 5. Melhores configurações de rede obtidas para cada tamanho do conjunto de treinamento

Número de exemplos no conjunto de treinamento	Algoritmo para o cálculo do parâmetro de largura da função radial	Número de unidades radiais	Algoritmo para o cálculo da posição dos hiper-centros
12	Isotrópico, Fator de escala = 10	9	Sub-amostragem
15	Isotrópico, Fator de escala = 10	12	Sub-amostragem
24	Isotrópico, Fator de escala = 10	12	Sub-amostragem
30	Isotrópico, Fator de escala = 10	23	Sub-amostragem
48	Isotrópico, Fator de escala = 10	36	K-Médias
60	Isotrópico, Fator de escala = 10	45	K-Médias
120	Isotrópico, Fator de escala = 10	60	Sub-amostragem
150	Isotrópico, Fator de escala = 10	75	K-Médias
240	Isotrópico, Fator de escala = 10	120	K-Médias
300	Isotrópico, Fator de escala = 10	150	Sub-amostragem
400	Isotrópico, Fator de escala = 10	200	Sub-amostragem
500	Isotrópico, Fator de escala = 10	250	Sub-amostragem

O fator x_2 (número de unidades radiais na camada oculta) foi significativo em todos os experimentos, embora seu peso relativo no desempenho das redes seja bem inferior ao do fator x_1 para experimentos com número de casos de treinamento igual ou superior a 24. Este fator foi o mais significativo no experimento com 15 casos. O fator x_3 (algoritmo para determinação da posição dos hiper-centros da função radial) foi o menos influente dos efeitos principais. Este fator, na verdade, mostrou efeito insignificante sobre o desempenho das redes nos experimentos realizados. A título de exemplo, mostra-se na Fig. (3) o diagrama de Pareto para os efeitos obtidos no experimento realizado com 24 exemplos. O valor adotado de α utilizado foi de 0.05. O diagrama mostra claramente a prevalência do fator x_1 sobre o desempenho da rede.

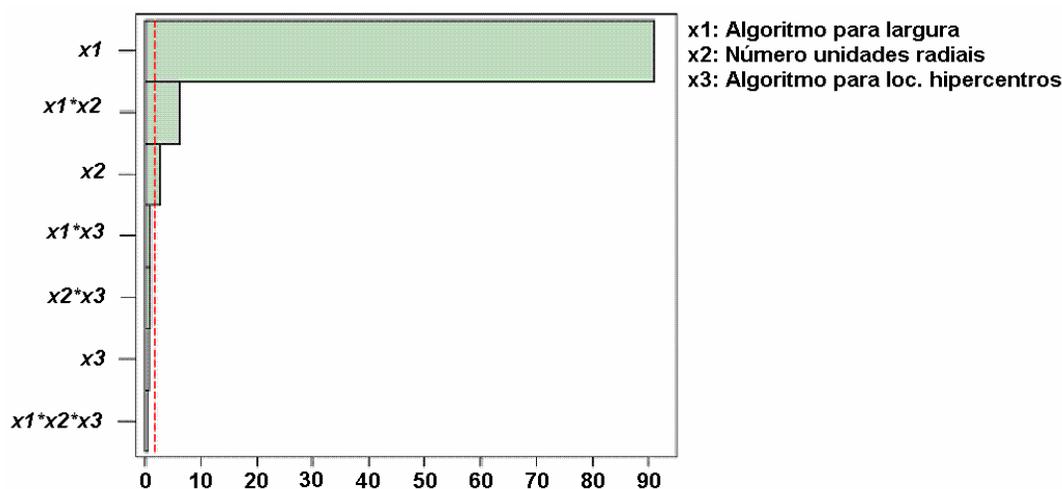


Figura 3. Diagrama de Pareto dos efeitos no experimento com 24 casos de treinamento

Com relação à existência de interações, todos os experimentos realizados apresentaram ao menos um efeito de interação apontado como significativo para o desempenho das redes, de acordo com os resultados da ANOVA. Em alguns experimentos os efeitos de interação de terceira ordem foram apontados como significativos. A interação existente entre níveis dos fatores x_1 e x_2 foi significativa em onze experimentos. O efeito desta interação é particularmente pronunciado. Ele rivaliza, e em alguns experimentos supera, os efeitos individuais do número de unidades radiais (fator x_2) nos experimentos. A interação entre os fatores x_1 e x_3 foi significativa em sete experimentos, ainda que com menor impacto. Os demais efeitos de interação apresentaram influência insignificante sobre o resultado.

O desempenho das melhores configurações de rede obtidas para predição da rugosidade superficial foi avaliado com base nos valores do erro na predição obtidos durante a fase de testes. Os resultados são sumarizados na Tab. (6).

Mostra-se os valores médios do erro, o desvio-padrão e o erro padrão para as configurações de rede descritas na Tab. (5). O erro na predição cai com o aumento do número de casos de treinamento. No melhor caso (500 casos de treinamento) a medida de erro atinge $3.0 \cdot 10^{-5}$, o que caracteriza excelente desempenho na predição. É importante, porém, salientar que uma medida de erro de 0.018 pôde ser obtida com apenas 24 casos de treinamento. Este resultado indica que redes RBF conseguem apresentar erros pequenos na predição com uma quantidade relativamente baixa de casos de treinamento. Observa-se que a dispersão da variável de saída cai à medida que o número de exemplos de treinamento aumenta.

Tabela 6. Propriedades dos modelos de predição da rugosidade pelas melhores redes obtidas

Número de exemplos de treinamento	Valor médio da medida do erro	Desvio-padrão da medida do erro	Erro-padrão
12	0,334699	0,226554	0,676889
15	0,047284	0,018055	0,381842
24	0,018287	0,005806	0,317493
30	0,014064	0,002929	0,208262
48	0,001678	0,000873	0,520262
60	0,000815	0,000298	0,365644
120	0,000569	0,000256	0,449912
150	0,00036	0,000158	0,438889
240	0,000143	5,25E-05	0,367133
300	5,31E-05	2,16E-05	0,40678
400	4,29E-05	1,94E-05	0,452214
500	3E-05	1,4E-05	0,466667

Outro teste foi realizado para confirmar estatisticamente as diferenças entre as médias observadas na Tab. (6). Todos os pares possíveis de redes descritas na Tab. (5) tiveram seus erros de predição comparados por meio de análise de variância. Pelo teste pôde-se constatar que os erros na predição entre as redes são diferentes e caem com o aumento do número de casos de treinamento disponíveis.

A mesma abordagem foi utilizada para comparar a variância entre as melhores configurações de rede. Testes de Levene (Brown e Forsythe, 1974) foram aplicados para a hipótese nula de variâncias iguais no erro de predição das melhores redes. Os resultados comprovaram a tendência à queda na dispersão, à medida que aumentou o número de casos de treinamento disponível.

Os efeitos sobre a exatidão e sobre a precisão das redes são ilustrados na Fig. (4). A figura mostra os diagramas de caixa das melhores configurações de rede para os experimentos contendo de 24 a 500 casos de treinamento. Os pontos indicam o valor médio do erro na predição, para as redes descritas na Tab. (6). Asteriscos indicam *outliers*. Os limites das caixas correspondem ao primeiro, segundo e terceiro quartis dos erros de predição medidos. Nota-se claramente tendência à redução no erro de predição e à redução da variabilidade das respostas das redes.

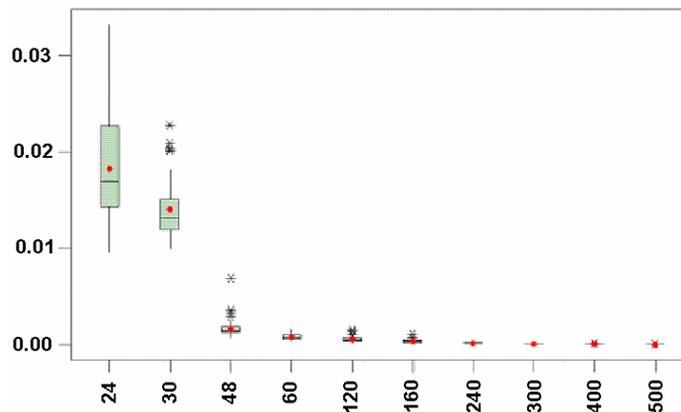


Figura 4. Diagrama de caixa do erro na predição e da dispersão do erro das melhores redes obtidas nos experimentos

5. CONCLUSÕES

O uso da metodologia de Projeto de Experimentos mostrou-se eficiente para a seleção de parâmetros de configuração de redes neurais de arquitetura RBF usadas na predição da rugosidade superficial em processo de

torneamento do aço SAE/ABNT 52100 – 55 HRC. A técnica utilizada possibilitou a configuração de redes de elevada exatidão e reduzida variabilidade na tarefa proposta. A análise realizada apontou, no melhor caso, uma configuração de rede com variável de medição do erro igual a $3.0 \cdot 10^{-5}$ e desvio-padrão igual a $1.4 \cdot 10^{-5}$. A exatidão das melhores configurações aumenta à medida que o número de casos disponível para treinamento aumenta. Inversamente, a variabilidade das melhores redes cai com o aumento do número de casos de treinamento.

Os resultados obtidos mostraram que redes treinadas com apenas 24 exemplos podem atingir medição do erro igual a 0.018. Este fato indica que redes neurais de arquitetura RBF são capazes de prever a rugosidade com bom nível de exatidão utilizando um número moderado de casos de treinamento.

O algoritmo para o cálculo do parâmetro de largura da função radial foi o fator mais influente entre os três fatores analisados. A influência do fator se torna dominante à medida que o número de exemplos disponíveis para treinamento aumenta. O algoritmo Isotrópico para determinação do parâmetro de largura, com fator de escala igual a 10, apresentou os melhores resultados em todos os experimentos realizados.

O segundo fator mais influente foi o número de unidades radiais na camada oculta. A proporção de $\frac{3}{4}$ entre o número de unidades radiais e o número de casos de treinamento foi predominante nos experimentos envolvendo até 60 casos de treinamento. Para experimentos com número de casos de treinamento superior a 60, a proporção de $\frac{1}{2}$ entre número de unidades radiais e número de casos de treinamento levou aos melhores resultados.

O fator menos influente foi o algoritmo para determinação da posição dos hiper-centros da função radial. A importância deste fator foi insignificante em quase todos os experimentos. Pode-se concluir que a opção por quaisquer dos dois algoritmos testados não leva a diferença significativa no desempenho das redes para a tarefa proposta. Tal fato pode simplificar ainda mais o projeto de redes RBF para predição da rugosidade.

Efeitos de interação entre os níveis dos fatores experimentais foram apontados como significativos para o desempenho das redes RBF na predição da rugosidade. Em cada experimento realizado ao menos um efeito de interação foi apontado como significativo pelo teste de análise de variância. Em alguns casos, efeitos de interação foram mais significativos para o desempenho da rede que efeitos principais tomados individualmente.

Deve-se enfatizar que as conclusões obtidas por este trabalho não se aplicam a outras arquiteturas de redes neurais nem a outros processos de usinagem, outros tipos de materiais ou ferramentas.

A mesma abordagem utilizada neste trabalho pode ser aplicada a diferentes arquiteturas de rede, tais como perceptron multi-camada. Um estudo da predição da rugosidade pode também ser feito usando-se o mesmo método aqui proposto aplicado a outro processo de usinagem ou a outro material.

6. REFERÊNCIAS

- Al-Ahmari, A.M.A., 2007, "Predictive machinability models for a selected hard material in turning operations", *Journal of Materials Processing Technology*, Vol. 190, pp. 305–311.
- Bagci, E., Işik, B., 2006, "Investigation of surface roughness in turning unidirectional GFRP composites by using RS methodology and ANN", *International Journal of Advanced Manufacture Technology*, Vol. 31, pp. 10–17.
- Balestrassi, P.P., Popova, E., Paiva, A.P., Marangon, J.W., 2008, "Design of Experiments on Neural Network's training for Nonlinear Time Series Forecasting", Vol. 72, in-press.
- Basheer, A.C., Dabade, U.A., Suhas, S.J., Bhanuprasad, V.V., 2008, "Modeling of surface roughness in precision machining of metal matrix composites using ANN", *Journal Of Materials Processing Technology*, Vol. 197, pp. 439–444.
- Benardos, P.G., Vosniakos, G.C., 2003, "Prediction of surface roughness in CNC in machining: a review", *International Journal of Machine Tools & Manufacture*, Vol. 43, pp.833-844.
- Benardos, P. G., Vosniakos, G. C., 2002, "Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments", *Robotics and Computer Integrated Manufacturing*, Vol. 18, pp.343-354.
- Bishop, C. M., 1995, *Neural Networks for Pattern Recognition*, Oxford University Press Inc., New York, USA, 504p.
- Bolanča, T., Cerjan-Stefanović, Š., Luša, M., Regelja, H., Lončarić, S., 2007, "Development of gradient elution retention model in ion chromatography by using radial basis function artificial neural networks", *Chemometrics and Intelligent Laboratory Systems*, Vol. 86, Issue 1, pp. 95-101.
- Bolanča, T., Cerjan-Stefanović, Š., Regelja, M., Regelja, H., Lončarić, S., 2005, "Development of an inorganic cations retention model in ion chromatography by means of artificial neural networks with different two-phase training algorithms", *Journal of Chromatography A*, Vol. 1085, Issue 1, pp. 74-85.
- Broomhead, D.S., Lowe, D., 1988, "Multivariable functional interpolation and adaptive networks", *Complex Systems*, Vol. 2, pp. 321-355.
- Brown, M.B., Forsythe, A.B., 1974, "Robust Tests for the Equality of Variances", *Journal of the American Statistical Association*, Vol. 69, pp. 364-367.
- Çaydas, U., Haşçalık, A., 2007, "A study on surface roughness in abrasive waterjet machining process using artificial neural networks and regression analysis method", *Journal Of Materials Processing Technology*, Vol. 202, pp. 574–582.
- Choudury, S.K., Bartarya, G., 2003, "Role of temperature and surface finish in prediction tool wear using neural network and design of experiments", *International Journal of Machine Tools & Manufacture*, Vol. 43, pp. 747-753.
- Cus, F., Zuperl, U., 2006, "Approach to optimization of cutting conditions by using artificial neural networks", *Journal of Materials Processing Technology*, Vol. 175, Issue 3, pp. 281-290.

- Dobrzanski, L.A., Trzaska, J., 2004, "Application of neural networks for prediction of critical values of temperatures and time of the supercooled austenite transformations", Journal of Materials Processing Technology, Vol. 155-156, pp. 1950-1955.
- El-Mounayri, H., Kishawy, H., Briceno, J., 2005, "Optimization of CNC ball end milling: a neural network-based model", Journal of Materials Processing Technology, Vol. 166, pp. 50-62.
- Erzurumlu; T., Oktem, H., 2007, "Comparison of response surface model with neural network in determining the surface quality of moulded parts", Materials and Design, Vol. 28, Issue 2, pp. 459-465.
- Haykin, S., 1998, "Neural Networks - A comprehensive foundation", Mcmillan Publishing Company, New York, USA, 842p.
- International Organization for Standardization, 2005, "ISO 4287:1997/Cor 2:2005 - Geometrical Product Specifications (GPS) – Surface texture: Profile method – Terms, definitions and surface texture parameters".
- Kim, Y.S., Yum, B.J., 2004, "Robust Design of Multilayer Feedforward Neural Networks: an experimental approach", Engineering applications of artificial intelligence, Vol. 38, pp. 1-15.
- Montgomery, D.C., 2004, "Design and Analysis of Experiments", Wiley, New York, USA, 660p.
- Oktem, H., Erzurumlu, T., Erzincanli, F., 2006, "Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm", Materials and Design, Vol. 27, pp. 735-744.
- Özel; T., Karpat, Y., 2005, "Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks", International Journal of Machine Tools and Manufacture, Vol. 45, pp. 467-479.
- Pereira, J. C. C., 2006, "Determinação de modelos de Vida de ferramenta e rugosidade no torneamento do aço ABNT 52100 Endurecido utilizando Metodologia de Superfície de Resposta (DOE)", Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Itajubá, 140p.
- Shaw, M., 2004, "Metal Cutting Principles", Oxford University Press, New York, USA, 672p.
- Sick, B., 2002, "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, Vol. 16, pp.487-546.
- Sonar, D.K., Dixit, U.S., Ohja, D.K., 2006, "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, Vol. 27, pp. 661-666.
- Trent, E.M., Wright, P.K., 2000, "Metal Cutting", Butterworth Heinemann, Woburn, USA, 446p.
- Zhong, Z. W., Khoo, L. P., Han, S.T., 2006, "Prediction of surface roughness of turned surfaces using neural networks", International Journal of Advanced Manufacture Technology, Vol. 28, pp. 688-693.

7. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído neste trabalho.

DESIGN OF EXPERIMENTS APPLIED TO THE PROJECT OF RBF NEURAL NETWORKS FOR THE PREDICTION OF SURFACE ROUGHNESS (R_a) IN TURNING PROCESS OF SAE/ABNT 52100 STEEL

Fabício José Pontes, fabriciojosepontes@uol.com.br¹

João Roberto Ferreira, jorofe@unifei.edu.br²

Anderson Paulo de Paiva, andersonppaiva@yahoo.com.br²

¹FEG-UNESP, Faculdade de Engenharia de Guaratinguetá-Universidade Estadual Paulista,

²UNIFEI, Universidade Federal de Itajubá

Abstract: *The statistical methodology of Design of Experiments (DOE) is applied in this work to specify parameters for artificial neural networks of Radial Basis Function (RBF) architecture. The networks are employed to the task of predicting surface roughness in the turning process of a SAE 52100 – 55 HRC steel. The experimental factors are the algorithm employed to specify the spread factor of radial units, the number of radial units and the algorithm employed to locate centers of radial functions. Experiments with training sets of distinct sizes were conducted, aiming to identify network configurations with high performance for each size of training set. Networks obtained proved capable of predicting roughness in accurate, precise and economically viable way. Results show that interaction effects between design parameters have significant impact on the performance of the RBF networks in the task proposed. The work concludes that the DOE methodology constitutes a better approach to the design of network instead of the most common trial and error approach.*

Keywords: *Design of Experiments, Surface roughness, Neural Networks, Turning, SAE 52100 Hardened Steel (55 HRC)*