

O EMPREGO DE REDES NEURAIS ARTIFICIAIS PARA A PREDIÇÃO DE RUGOSIDADE PROVENIENTE DO PROCESSO DE TORNEAMENTO DO ALUMÍNIO ABNT 6262

Andreia A. L. Ferreira, ferrarisportbrasil@hotmail.com¹

Jacqueline Micheletti Cilento, jackih.88@gmail.com¹

Nelson Wilson Paschoalinoto, nelson.paschoalinoto@sp.senai.br²

Aderval Ferreira de Lima Filho, aderval.filho@sp.senai.br²

¹Anhanguera Educacional Ltda. Alameda Maria Tereza, 4266 Valinhos, SP - CEP 13278-181 rc.ipade@aesapar.com

²Faculdade SENAI de Tecnologia Mecatrônica, Rua Santo André, 680 – São Caetano do Sul-SP

Resumo: O enfoque deste trabalho contou com a predição da rugosidade na superfície de corpos de prova de Alumínio ABNT 6262 após usinagem. Ensaios de usinagem de torneamento foram efetuados de acordo com um planejamento experimental, utilizando-se dois insertos diferentes. Os testes foram executados em 40 amostras de alumínio ABNT 6262. Para alimentar a rede neural artificial, os dados de corte utilizados no torneamento foram definidos como variáveis independentes enquanto os dados de rugosidade foram obtidos por meio da leitura de um rugosímetro. Obteve-se correlação entre os resultados desejados e os previstos pelas redes. A predição torna-se importante para otimizar o tempo e custos para as empresas.

Palavras-chave: Redes Neurais Artificiais, Usinagem, Predição.

1. INTRODUÇÃO

A busca de melhorias de processos e otimização de tempo e custos se tornou foco constante no modelamento e otimização do processo produtivo das indústrias em geral (SANTOS, 2001). Observando esse aspecto, o presente trabalho objetivou a predição da rugosidade superficial com o auxílio de Redes Neurais Artificiais – RNA, utilizando corpos de prova de Alumínio ABNT 6262.

O objetivo de uma rede neural é projetar através de um modelo matemático o comportamento dos neurônios biológicos. Isso ocorre por serem sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não lineares). As unidades ficam dispostas em camadas interligadas por um vasto número de conexões geralmente unidirecionais, cujas conexões armazenam o conhecimento adquirido ponderando a entrada de cada neurônio e associando-os a um determinado peso. (BRAGA, 2012).

O primeiro passo desta pesquisa consistiu em obter dados reais de usinagem através dos ensaios em laboratório das amostras do material que alimentará esta respectiva rede neural artificial para ser treinada. O treinamento da rede é uma etapa crucial. Com os dados do treinamento pode-se testar a eficiência da rede em prever resultados similares à prática. De posse destes dados escolheu-se variáveis independentes importantes para a obtenção da rugosidade que foram inseridas na rede para futuramente efetuar as predições, antes da execução da usinagem.

2. OBJETIVO

O objetivo consistiu na criação de uma RNA que tenha a capacidade de prever a rugosidade de uma peça baseando-se nas variáveis de entrada controladas. A análise da influência dos dados de corte e suas correlações com a rugosidade é praticada. Um tratamento estatístico foi realizado levando-se em conta os ensaios de torneamento realizados.

3. METODOLOGIA

O torneamento de corpos de prova foi realizado em um comprimento de 40mm conforme Fig. (1) sem a utilização de fluido de corte. A rugosidade resultante deste processo foi medida por um rugosímetro.



Figura 1. Exemplos de corpos de prova.

Com os dados de usinagem obtidos e da rugosidade dos corpos de prova foi realizado um planejamento estatístico para poder constatar possíveis correlações. Como variáveis independentes foram determinadas a geometria do inserto, o avanço (f), a velocidade de corte (V_c) e a penetração da ferramenta (a_p). Como variável fixa foram estipuladas a usinagem a seco, o material, a dureza dos corpos de prova e a máquina utilizada para a realização dos ensaios e, como variável dependente foram utilizados os dados de rugosidade média dos corpos de prova (R_a).

Com posse dos dados, a rede neural artificial foi implementada por meio da ferramenta “nntool” disponível no software MATLAB, treinada e testada para prever a rugosidade do corpo de prova.

Em geral a RNA é caracterizada tendo todas as variáveis independentes citadas como “entradas” da rede neural e a rugosidade como “target” do processamento, fornecendo o valor de rugosidade futura como dado de saída.

4. MATERIAIS E MÉTODOS EXPERIMENTAIS

4.1. Ensaio de Usinagem

Para a execução da usinagem dos corpos de prova foram utilizados dois insertos distintos. Estes foram denominados como Inserto 1 (**VCGX 16 04 04-AL H10**) e Inserto 2 (**VCGX 16 04 08-AL H10**). Utilizou-se para a usinagem o torno MAZAK 15N da Faculdade SENAI de Tecnologia Mecatrônica. A Fig. (2) ilustra o torno utilizado e a geometria do inserto.



Figura 2. Torno MAZAK e Geometria do inserto de corte.

Os corpos de prova de alumínio foram separados em 2 lotes. O primeiro, com 20 amostras foram divididos em 10 ensaios e 10 réplicas, totalizando 20 ensaios. Da mesma forma procedeu-se para o segundo inserto. Para uma maior facilidade dividiu-se as operações dos insertos por cores. Para o inserto tipo 1, foi instituída a cor verde e para o inserto tipo 2 a cor vermelha. A Tab. (1) ilustra o planejamento de usinagem utilizado. A coluna “P” refere-se à aresta do inserto de corte utilizada. A letra “R” indica que o respectivo ensaio é uma réplica.

Tabela 1. Planejamento experimental utilizado para a usinagem.

CP	P	A	Vc	f	ap
1	1		300,00	0,15	0,50
2	1		400,00	0,15	0,50
3	1		300,00	0,25	0,50
4	1		400,00	0,25	0,50
5	1		300,00	0,15	1,00
6	2		400,00	0,15	1,00
7	2		300,00	0,25	1,00
8	2		400,00	0,25	1,00
9	2		350,00	0,20	0,75
10	2		350,00	0,20	0,75
11	1	R	300,00	0,15	0,50
12	1	R	400,00	0,15	0,50
13	1	R	300,00	0,25	0,50
14	1	R	400,00	0,25	0,50
15	1	R	300,00	0,15	1,00
16	2	R	400,00	0,15	1,00
17	2	R	300,00	0,25	1,00
18	2	R	400,00	0,25	1,00
19	2	R	350,00	0,20	0,75
20	2	R	350,00	0,20	0,75

CP	P	A	Vc	f	ap
1	1		300,00	0,15	0,50
2	1		400,00	0,15	0,50
3	1		300,00	0,25	0,50
4	1		400,00	0,25	0,50
5	1		300,00	0,15	1,00
6	2		400,00	0,15	1,00
7	2		300,00	0,25	1,00
8	2		400,00	0,25	1,00
9	2		350,00	0,20	0,75
10	2		350,00	0,20	0,75
11	1	R	300,00	0,15	0,50
12	1	R	400,00	0,15	0,50
13	1	R	300,00	0,25	0,50
14	1	R	400,00	0,25	0,50
15	1	R	300,00	0,15	1,00
16	2	R	400,00	0,15	1,00
17	2	R	300,00	0,25	1,00
18	2	R	400,00	0,25	1,00
19	2	R	350,00	0,20	0,75
20	2	R	350,00	0,20	0,75

4.2. Medições

Para uma maior confiabilidade, foram realizadas medições de rugosidade em cada corpo de prova na direção do avanço e a média destes valores foi utilizada como parâmetro dependente da rede neural artificial. Foi utilizado um rugosímetro Handysurf E-35A da Zeiss. Este pode ser visualizado na Fig. (3).



Figura 3. Rugosímetro utilizado.

5. RESULTADOS E DISCUSSÕES

Neste tópico estão listados os resultados das medições de rugosidade, os treinamentos e testes das redes neurais artificiais utilizadas e a influência dos parâmetros de usinagem em relação à rugosidade.

5.1 Rugosidade Média

Na Tab. (2) encontram-se os resultados da rugosidade média Ra. Foram tomadas cinco medições em posições distintas na direção do avanço. A média foi utilizada como parâmetro dependente da rede neural artificial.

Tabela 2. Resultados de medição de rugosidade média.

RUGOSIDADE - Ra 1							RUGOSIDADE - Ra 2						
CP	Leitura 1	Leitura 2	Leitura 3	Leitura 4	Leitura 5	Média	CP	Leitura 1	Leitura 2	Leitura 3	Leitura 4	Leitura 5	Média
1	0,8	0,8	0,8	0,7	0,7	0,8	1 (2)	2,2	2,2	2,2	2,1	2,1	2,2
2	1,2	1,1	1,1	1,4	1,3	1,2	2 (2)	2,1	2,1	2,1	2,2	2,0	2,1
3	3,1	3,1	3,1	3,0	3,0	3,1	3 (2)	5,7	5,7	5,7	5,7	5,6	5,7
4	2,9	3,0	2,9	2,8	2,9	2,9	4 (2)	5,4	5,6	5,6	5,3	5,3	5,4
5	0,8	0,8	0,8	0,8	0,8	0,8	5 (2)	1,9	1,9	1,9	2,0	2,0	2,0
6	1,1	1,2	1,1	1,0	1,1	1,1	6 (2)	2,0	2,0	2,1	2,1	2,1	2,1
7	2,7	2,4	2,7	2,5	2,4	2,5	7 (2)	6,7	6,4	6,5	6,2	6,2	6,4
8	2,8	3,0	2,7	2,6	2,7	2,8	8 (2)	5,8	5,7	5,8	5,6	5,4	5,7
9	1,7	1,8	1,9	1,7	1,7	1,7	9 (2)	3,6	3,8	3,6	3,5	3,5	3,6
10	1,8	1,8	1,8	1,8	1,7	1,8	10 (2)	4,5	4,5	4,5	4,2	4,5	4,4
11	0,9	0,9	0,9	0,8	0,9	0,9	11 (2)	2,0	2,0	2,0	2,1	2,1	2,0
12	1,1	1,1	1,1	1,0	1,0	1,1	12 (2)	2,1	2,1	2,1	2,1	2,0	2,1
13	3,0	2,9	2,8	2,9	2,8	2,9	13 (2)	5,7	5,8	5,8	5,9	5,9	5,8
14	2,6	2,8	2,6	2,6	2,6	2,6	14 (2)	5,7	5,6	5,7	5,9	5,8	5,7
15	1,0	1,0	1,0	1,0	0,9	1,0	15 (2)	2,2	2,3	2,2	2,2	2,1	2,2
16	1,4	1,4	1,4	1,3	1,3	1,4	16 (2)	2,4	2,4	2,4	2,2	2,2	2,3
17	2,8	2,7	2,6	2,5	2,5	2,6	17 (2)	5,9	5,7	5,9	5,8	5,6	5,8
18	2,9	2,8	2,9	2,9	2,9	2,8	18 (2)	5,8	5,8	5,7	5,6	5,7	5,7
19	1,7	1,7	1,9	1,7	1,6	1,7	19 (2)	3,8	3,8	3,9	3,6	3,5	3,7
20	1,9	1,7	1,9	1,7	1,7	1,8	20 (2)	3,9	3,9	3,9	3,7	3,7	3,8

5.2 Treinamento e teste das RNAs

Uma rede neural artificial supervisionada foi criada para cada inserto, respeitando-se o planejamento experimental utilizado na usinagem e o resultado médio de rugosidade obtida. Utilizou-se a ferramenta nntool do software Matlab. Muitas redes foram treinadas e testadas e encontram-se aqui as que obtiveram melhores respostas. Os dados foram replicados quatro vezes totalizando 60 entradas da rede. As redes foram chamadas de REDE 1, confeccionada com dados do inserto 1 e REDE 2, criada baseada nos dados do planejamento do inserto 2. A arquitetura das redes pode ser visualizada na Fig. (4).




Figura 4. Arquitetura das RNAs utilizadas.

Para o treinamento da rede 1, tomou-se 15 amostras aleatórias do planejamento, reservando-se 5 para testes e validação posterior. As amostras utilizadas para o treinamento foram 2, 3, 4, 5, 6, 9, 10, 11, 12, 14, 15, 16, 17, 18 e 20. Neste treinamento utilizou-se uma rede Perceptron multicamadas com duas camadas (MLP). Para o treinamento do INSERTO 1 utilizou-se 10 neurônios na primeira camada. A função de treinamento foi a Trainlm. Utilizou-se também o erro médio quadrático (MSE) e a função de transferência tangente sigmoide. O resultado deste treinamento e seu teste estão ilustrados na Fig. (5). Nestes gráficos a rugosidade medida está representada pela linha vermelha e a predição da rede pela cor azul tracejada.




Figura 5. Treinamento e teste da REDE 1.

Para o treinamento da rede 2, tomou-se 15 amostras aleatórias do planejamento, reservando-se 5 para testes e validação posterior. As amostras utilizadas para o treinamento foram 1, 2, 4, 5, 6, 7, 9, 10, 11, 13, 15, 16, 17, 18 e 20. Neste treinamento utilizou-se uma rede Perceptron multicamadas com duas camadas (MLP). Para o treinamento do INSERTO 2 utilizou-se 10 neurônios na primeira camada. A função de treinamento foi a Trainlm. Utilizou-se a soma dos erros quadráticos (SSE) e a função de transferência tangente sigmoidal. O resultado deste treinamento e seu teste estão ilustrados na Fig. (6). Nestes gráficos a rugosidade medida está representada pela linha vermelha e a predição da rede pela cor azul tracejada.




Figura 6. Treinamento e teste da REDE 2.

Para uma melhor análise estão listados na Tab.(3) os resultados dos testes da REDE 1 e da REDE 2. Nestas tabelas foram listados os valores medidos, os valores estimados pelas RNAs e o cálculo do erro percentual relativo.

Tabela 3. Comparação entre os valores medidos, obtidos pela rede neural artificial e respectivo erro relativo.

REDE 1	Medido	0,8	2,6	2,8	2,9	1,7
	RNA	0,901208	2,599651	2,799693282	3,084665	1,79961
	ERRO (%)	-12,651	0,0001344	0,00010954229	-6,36777	-5,8594
REDE 2	Medido	5,7	5,7	2,1	5,7	3,8
	RNA	5,8	5,8	2,1	5,4	3,925
	ERRO (%)	-1,75439	-1,75439	-1,14856E-09	0,0526315	-3,28947

5.3 Resultados Estatísticos

Foi criado um planejamento fatorial com dois níveis e três fatores (2^3) com dois pontos centrais, incluindo as réplicas, totalizando 20 ensaios para cada inserto com um intervalo de confiança de 95%. Para isto, utilizou-se o software Statistica 12, versão *trial*. Com esta análise buscou-se verificar a influência de um conjunto de fatores na variável dependente R_a . Para o inserto tipo 1 notou-se que o avanço f , a velocidade de corte V_c e a interação entre o avanço f e a velocidade de corte V_c influenciam a rugosidade R_a . Para o inserto tipo 2, observou-se que a rugosidade R_a foi influenciada somente pelo avanço f . A figura 7 ilustra respectivamente o gráfico de Pareto resultado do planejamento para o inserto 1 e 2. A figura 8 mostra a superfície de resposta de $V_c \times f$ para os insertos 1 e 2.




Figura 7. Gráficos de Pareto do inserto 1 e inserto 2.




Figura 8. Superfície de resposta do inserto 1 e inserto 2: parâmetro R_a .

As Eq. (1) e (2) mostram a relação de V_c e f para a obtenção do parâmetro R_a dos insertos 1 e 2.

$$R_{a1} = -3,9272968750001 + 0,044312500000001 * y + 32,9578125 * x - 0,03259375 * x * y + 0,0050062499999999 * y^2 - 5,1062500000002 * y^2 * x - 6,0515625 \quad (1)$$

$$R_{a2} = -5,1820000000001 + 0,062468750000002 * y + 44,93125 * x - 0,032562500000001 * x * y - 0,0011750000000001 * y^2 + 4,3874999999997 * y^2 * x - 1,1203125 \quad (2)$$

5.4 Considerações Finais

Percebeu-se que a variável que mais influenciou a rugosidade para o inserto tipo 1 foi o avanço. Além deste, a velocidade de corte e a interação avanço e velocidade de corte também influenciam a rugosidade. No inserto tipo 2, a rugosidade somente foi influenciada pelo avanço.

Notou-se que o aumento do avanço aumenta o valor da rugosidade média.

As redes neurais artificiais treinadas e testadas conseguiram cumprir o papel da predição da rugosidade antes da usinagem para as condições estipuladas. Conforme previsto, as redes conseguiram valores muito próximos dos desejados.

6. AGRADECIMENTOS

À Faculdade SENAI de Tecnologia Mecatrônica pelo auxílio na usinagem dos corpos de prova. À escola SENAI A. Jacob Lafer pelo auxílio na medição de rugosidade. Ao professor Militão e a todos que contribuíram de alguma forma para o desenvolvimento deste trabalho.

7. REFERÊNCIAS

- Braga, Antônio de Pádua; Carvalho, André Ponce de Leon F. de; Ludermir, Teresa Bernarda. “Redes Neurais Artificiais Teoria e Aplicações”, Rio de Janeiro, 2.ed., p. 3, LTC, 2012.
- Paschoalinoto, Nelson Wilson; Tolosa, Thiago Antonio Grandi de; Delijaicov, Sergio; Bordinassi, Ed Claudio. “A utilização de redes neurais artificiais para a predição de acabamento superficial proveniente do processo de torneamento do aço ABNT 52100”. CONEM 2012. VII Congresso Nacional de Engenharia Mecânica, São Luis, Maranhão, Brasil.
- Paschoalinoto, Nelson Wilson. “Redes neurais artificiais e planejamento fatorial: um estudo da integridade superficial do aço ABNT 52100 endurecido no processo de torneamento”. São Bernardo do Campo, 2013. 191 f. Dissertação (Mestrado) - Centro Universitário da FEI, 2012.
- Pontes, Fabrício José. “Projeto otimizado de redes neurais artificiais para a predição da rugosidade no torneamento de aços endurecidos com a utilização da metodologia de superfície de resposta”, Revista P&D em Engenharia de Produção V. 08 N. 01 (2010) p. 33-37.
- SANTOS, André Luis Beloni dos. “Metodologia via redes neurais para a estimativa da rugosidade e do desgaste da ferramenta de corte no processo de fresamento frontal”, tese de doutorado, UFU, 2001.

8. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.

THE USE OF ARTIFICIAL NEURAL NETWORKS TO PREDICTION OF SURFACE ROUGHNESS FROM THE TURNING PROCESS OF THE ALUMINUM ABNT 6262

Andreia A. L. Ferreira, ferrarisportbrasil@hotmail.com¹

Jacqueline Micheletti Cilento, jackih.88@gmail.com¹

Nelson Wilson Paschoalinoto, nelson.paschoalinoto@sp.senai.br²

Aderval Ferreira de Lima Filho, aderval.filho@sp.senai.br²

¹Anhanguera Educacional Ltda. Alameda Maria Tereza, 4266 Valinhos, SP - CEP 13278-181 rc.ipade@aesapar.com

²Faculdade SENAI de Tecnologia Mecatrônica, Rua Santo André, 680 – São Caetano do Sul-SP

Abstract: The focus of this work was the use of artificial neural networks to the prediction of surface roughness. Turning machining tests were effectuated according to a design of experiments, using two different inserts. The tests were performed in 40 samples of ABNT 6262. The cutting parameters used in the turning of the samples were defined as network variables. A good approximation between the desired and the planned results by the networks was obtained. Prediction becomes important to optimize time and costs for industry.

Keywords: artificial neural networks, turning process, machining.