

UMA FERRAMENTA NEURAL PARA PREVISÃO DE RUGOSIDADE EM PROCESSOS DE TORNEAMENTO DE AÇO COM FERRAMENTAS CONVENCIONAIS
DEMerval MIZUYAMA, CARLOS ELIAS DA SILVA JÚNIOR, ALESSANDRO GOEDEL, CLAYTON LUIZ GRACIOLA.

Departamento de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná (UTFPR-CP)
Programa de Pós-Graduação em Engenharia Elétrica
Av. Alberto Carazzai, 1640, Cornélio Procópio, PR, CEP 86300-000
E-mails: mizuyama@utfpr.edu.br, cesilva@utfpr.edu.br, agoedel@utfpr.edu.br, claytongraciola@gmail.com.

Abstract— *The turning machines are widely found in the metal-mechanic sector. These equipments are powered by induction motors which are coupled through a load of belts, gears or straight shaft and are subjected to disturbances in the quality of energy. The purpose of this paper is to present a predictor of surface roughness of parts based on the values of the effective current that feeds induction motor of a lathe in a turning process using artificial neural networks. Simulation and experimental results are presented to validate the performance of the proposed method in different operating situations with unbalance voltage and machining conditions.*

Keywords— AC induction motor, turning process, power quality, artificial neural network, surface roughness.

Resumo— Os tornos mecânicos são amplamente utilizados no setor metal-mecânico. Estes equipamentos são acionados por motores de indução trifásicos, os quais estão acoplados à carga através de correias, engrenagens ou diretamente por um eixo e ficam submetidos aos distúrbios da qualidade de energia elétrica. A proposta deste trabalho consiste em apresentar um preditor de rugosidade superficial de peças baseada nos valores das correntes eficazes que alimentam o motor de indução trifásico de um torno mecânico em um processo de torneamento utilizando redes neurais artificiais. Resultados de simulação e experimentais são apresentados para validar a performance do método proposto em diversas situações de operação combinando desequilíbrios de tensão e condições de usinagem.

Palavras-chave— Motor de indução trifásico, processo de torneamento, qualidade de energia, redes neurais artificiais, rugosidade superficial.

1 Introdução

Os processos de usinagem estão presentes em diversas indústrias do setor metal-mecânico. Usinagem é a denominação genérica dos processos industriais de fabricação mecânica que conferem à peça usinada a sua forma, as dimensões ou o seu acabamento superficial pela remoção de material de uma peça (cavaco) devido à ação de corte exercida por uma ferramenta (Ferraresi, 1977). Estes processos produzem falhas de superfície, denominadas ondulações e rugosidade, as quais podem influenciar o desempenho do componente usinado (DeGarmo et al., 2008).

As máquinas-ferramentas utilizadas nos processos de usinagem são acionadas por motores elétricos. Segundo Lacalle et al., (2009), em sua maioria, os motores mais utilizados neste emprego são os Motores de Indução Trifásicos (MIT).

O motor de indução trifásico (MIT) tem por característica a distribuição senoidal simétrica dos enrolamentos do estator e do rotor. Quando um conjunto de correntes trifásicas simétricas defasadas de 120 graus alimentam o enrolamento do estator, igualmente defasados de 120 graus, cria-se um campo magnético girante constante, o qual se desloca a uma velocidade angular igual à sua frequência de alimentação. Neste caso, o cálculo do torque em regime permanente leva em consideração os parâmetros elétricos do motor pela análise do circuito equivalente (Krause et

al., 2002; Krishnan, 2001; Ong, 1997 e Fitzgerald et al., 2006).

Porém, quando a alimentação do motor não é equilibrada o vetor campo girante apresenta característica pulsante, a qual depende da amplitude do desequilíbrio entre as fases da tensão de alimentação. No caso do MIT ser alimentado por tensões desequilibradas deve-se considerar componentes de sequência negativa da tensão associando um campo girante de mesma frequência com sentido de rotação inverso àquele da sequência positiva. Este fenômeno é decorrente dos problemas de qualidade de energia na rede de alimentação do motor e implica em alteração da rugosidade superficial de peças obtidas em processos de torneamento, influenciando no acabamento do produto final. A rugosidade, aferida por meio do emprego de um rugosímetro, é um dos parâmetros de qualidade das peças usinadas.

Trabalhos recentes têm utilizado modelos preditores para inferir os níveis de rugosidade das peças durante o processo de fabricação. As técnicas convencionais utilizam os valores do avanço, do raio de ponta da ferramenta e da velocidade de corte para a predição da rugosidade, conforme Özel et al., (2009) e Pontes et al., (2010). Upadhyay, Vikas; Jain, P.K. e Mehta, N.K. (2013) realizaram a predição de rugosidade superficial no torneamento utilizando os parâmetros de corte, bem como os sinais de vibração.

Considerando os parâmetros de corte, o avanço é o principal fator que exerce influência sobre a rugosidade superficial da peça usinada, seguido pelo raio de ponta da ferramenta e pela velocidade de

corde. A profundidade de corte não têm qualquer efeito significativo sobre a rugosidade da superfície. (Makadia, Ashvin J.; Nanavati, J.I., 2013).

No trabalho de Özel e Karpát (2005) os resultados apresentados para predição da rugosidade superficial e desgaste da ferramenta utilizaram a análise de regressão e modelos de redes neurais no torneamento de acabamento em aço endurecido. Eles demonstraram que o preditor neural pode inferir o padrão de rugosidade da superfície da peça no processo de torneamento.

Este trabalho propõe uma abordagem baseada em rede neural artificial para prever a rugosidade superficial de uma peça em um processo de torneamento usando uma rede neural artificial multicamadas, considerando as entradas eficazes da corrente sob condições diversas de cargas aplicadas ao rotor do MIT e de desequilíbrios de tensão.

A organização deste trabalho é descrita a seguir: Na Seção 2 são apresentados os aspectos da modelagem do MIT. Na Seção 3 é descrito o método de usinagem e de predição da rugosidade superficial em processos de torneamento. Na Seção 4 são abordados os aspectos relacionados à RNA e sua aplicação na metodologia proposta. Finalmente, na Seção 5 são apresentadas as conclusões deste trabalho.

2 Fundamentos de Redes Neurais

Os Sistemas Inteligentes (SI) têm-se apresentado como uma ferramenta eficaz na solução de diversos problemas de engenharia. Dentre os SI destacam-se as RNAs, as quais são utilizadas neste trabalho como estimador de rugosidade num processo de torneamento. Segundo Zain et al. (2009), a RNA pode ser aplicada para investigar o acabamento superficial para diferentes parâmetros e tipos de processos de usinagem.

As redes neurais artificiais estão sendo amplamente utilizadas em vários aspectos do processo de fabricação para ajudar o ser humano a produzir produtos de alta qualidade, dentro do prazo e a um custo mínimo. Verifica-se que as redes neurais podem ser utilizadas para encontrar as estimativas eficazes de rugosidade superficial. (Abhang, L.B.; Hameedullah, M., 2012).

Sistemas baseados em RNA possuem elevadas taxas de computação por utilizarem um número elevado de elementos processadores simples massivamente conectados. Assim, tais modelos têm as seguintes características: (i) capacidade intrínseca de operação em paralelo; (ii) não há a necessidade de conhecimento a priori dos modelos matemáticos do sistema; (iii) sistemas inspirados no cérebro humano; (iv) habilidade de aprender a partir da experiência (Haykin, 2008).

A arquitetura das RNAs utilizada no desenvolvimento deste trabalho é a rede *Perceptron* Multicamadas (PMC).

3 Rugosidade Superficial

A superfície das peças usinadas, por mais perfeitas que sejam, apresenta irregularidades que correspondem à combinação de rugosidade superficial (ou erro micro geométrico) e as ondulações e falhas (que são os erros macro geométricos ou erros de forma). Assim, a exigência do acabamento superficial aumenta à medida que crescem as exigências de projeto, as quais devem ser adequadas ao tipo de função que o componente usinado irá exercer (Souza, 2011).

Desta forma, a rugosidade está relacionada com a melhoria da qualidade de superfície de peças mecânicas, redução de custos e maiores benefícios econômicos. (Huang, Jiming; Zhang, Wenbin; Chen Rongqiang, 2011).

3.1 Modelos Preditores de Rugosidade

Muitos pesquisadores têm utilizado métodos alternativos aos tradicionais para a análise de rugosidade em processos de usinagem. Neste contexto, as redes neurais artificiais desempenham importante papel na análise dos processos de torneamento, tendo por objetivo a previsão da rugosidade superficial, a vida da ferramenta e outros parâmetros.

Bernardo e Vosniakos (2003) fizeram uma extensa revisão da literatura sobre a predição da rugosidade superficial na usinagem e confirmaram a eficácia das abordagens das redes neurais artificiais.

Rugosidade da superfície pode ser prevista dentro de um razoável grau de precisão, considerando o avanço, a velocidade de corte, profundidade de corte e os sinais de vibração nos três eixos ortogonais (x, y, z) do suporte da ferramenta, como parâmetro de entrada. (Asiltürk, İlhan; Ünüvar, Ali, 2010).

Özel e Karpát (2005) apresentaram resultados de predição da rugosidade superficial e desgaste da ferramenta usando a análise de regressão e de modelos de redes neurais para torneamento de aço. Karpát e Özel (2005, 2006a, 2006b) apresentaram redes neurais para a seleção de parâmetros de usinagem para melhor acabamento, desgaste da ferramenta e tempo de usinagem. O modelo obtido através de regressão linear é apresentado na Equação (1).

$$R_a = 9,8963V_c^{-0,15819} f^{1,1904} r_e^{-0,92248} \quad (1)$$

onde:

R_a é a rugosidade superficial (μm);

V_c é a velocidade de corte (m/min.);

f é o avanço (mm/volta);

r_e é o raio de ponta da ferramenta (mm).

Esta equação foi utilizada neste trabalho para simular a rugosidade de uma peça quando a máquina-ferramenta está acoplada a um motor de indução trifásico, submetido à variação de conjugado de carga e desbalanços de tensão. Esta metodologia é apresentada na próxima subseção.

As condições de usinagem consideradas no presente estudo foram as seguintes: raio de ponta da

ferramenta r_ϵ (raio de ponta) = 0,4 mm; f (avanço) = 0,075 mm/volta; V_c (velocidade de corte) = 345 m/min. O material da peça é o aço SAE 1045 trefilado.

3.2 Resultados de simulação

A primeira etapa de validação da proposta foi realizada utilizando o software *Matlab/Simulink*. A metodologia para treinamento e validação da estrutura neural proposta neste trabalho, os parâmetros de entrada da Rede Neural Artificial (RNA) *Perceptron* Multicamadas (PMC) são formados pelos valores eficazes (RMS) da corrente de linha da alimentação do MIT (Motor de Indução Trifásico) de acionamento da máquina-ferramenta (torno). A saída da RNA é a rugosidade estimada. A saída deste estimador neural é comparada com o valor desejado, gerando-se assim o sinal de Erro Relativo Médio (ERM), conforme mostra a Figura 1.

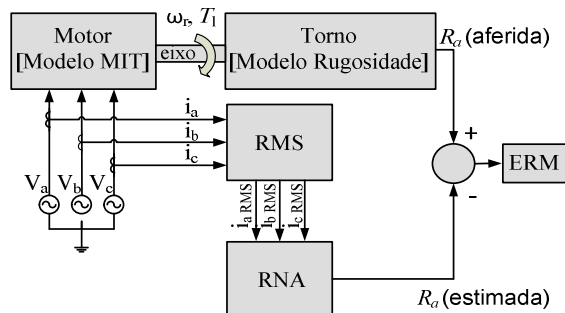


Figura 1. Estrutura do preditor de rugosidade

Os dados de treinamento considerados para as condições de desequilíbrio de tensões empregadas são variados de 0% a +/-10% de desequilíbrio em 9 condições de teste.

Para as 9 condições citadas, foram aplicados degraus de carga no motor de 6,3 CV (torque nominal de 25,2 Nm) de 1,008 Nm até 25,2 Nm, gerando assim 259 curvas de simulação.

Com o objetivo de gerar os dados de treinamento do estimador neural de velocidade do motor de indução em diversos pontos de operação de velocidade, foram realizadas várias simulações utilizando a ferramenta computacional *Matlab/Simulink*.

Para a validação, foram utilizadas duas condições de valores diferentes de desequilíbrio de tensão quando comparados com as utilizadas no processo de treinamento, conforme ilustrados na Tabela 1. Essas duas condições foram escolhidas aleatoriamente.

Tabela 1. Parâmetros de desequilíbrios utilizados na validação

Condição	Va (%)	Vb (%)	Vc (%)
1	+8	-3	0
2	+6	-9	0

A Figura 2 mostra os resultados de validação da RNA para a rugosidade na condição 1.




Figura 2. Curvas de validação de rugosidade (R_a): condição 1

A Tabela 2 apresenta o Erro Relativo Médio (ERM) e o Desvio Padrão (Dp) calculado entre os valores de rugosidade (R_a) de referência (rugosidade aferida) e os obtidos pela rede neural (rugosidade estimada).

Tabela 2. Erro Relativo Médio (ERM) e Desvio Padrão (Dp)

Condição	ERM (%)	Dp (%)
1	0,0115	0,0044
2	0,0120	0,0046

Os resultados de simulação apresentados nesta Seção confirmam o uso das redes neurais artificiais para estimar a rugosidade em peças torneadas, a partir das correntes trifásicas eficazes quando submetido a diferentes cargas e uma ampla faixa de tensão.

4 Resultados experimentais

A fim de investigar a influência da qualidade de energia elétrica sobre o acabamento superficial dos corpos de prova usinados, foram impostas condições de desequilíbrio na fase "C" da rede de alimentação trifásica (tensão de fase de 220 V) do motor da máquina-ferramenta utilizada nos ensaios de usinagem (torno). As condições de desequilíbrio foram de -1% a -10% para afundamento de tensão (*sag*) e de +1% a +10% para elevação de tensão (*swell*), com variação da tensão de 1% em 1% em ambas as situações, além da condição equilibrada e de falta de fase. A Figura 3 apresenta a representação esquemática da proposta do trabalho.




Figura 3. Representação esquemática da proposta do trabalho

A função de ativação da primeira camada escondida e da segunda camada escondida é a função tangente hiperbólica enquanto que a da camada de saída é a função linear.

A Tabela 3 apresenta os diversos parâmetros usados no treinamento da rede neural proposta pelo método de validação cruzada.

Tabela 3. Parâmetros da rede neural artificial proposta.

Arquitetura da rede	Perceptron multicamadas
Tipo de treinamento	Supervisionado
Número de camadas	6
Neurônios da 1ª camada escondida	5
Neurônios da 2ª camada escondida	10
Neurônios da 3ª camada escondida	17
Neurônios da 4ª camada escondida	12
Neurônios da 5ª camada escondida	3
Neurônios da camada de saída	1
Algoritmo de treinamento	Levenberg-Marquardt <i>backpropagation</i>
Taxa de Aprendizado	0,01
Épocas	4000
Erro quadrático requerido	$1e^{-11}$
Função de ativação das camadas intermediárias	Tangente hiperbólica
Função de ativação da camada de saída	Linear
Quantidade de amostras de treinamento	132 curvas - 10 pontos por curva
Quantidade de amostras de teste	132 curvas - 140 pontos por curva

Foram realizados ensaios experimentais de usinagem considerando 12 condições de ensaios.

A fim de tornar os resultados experimentais mais claros, a análise será feita da condição 1 a 12 utilizando filtro mediano com ordem 400.

A figura 4 ilustra o resultado de generalização da RNA utilizando o filtro mediano de ordem 400 para todas as 12 condições de ensaio empregadas.




Figura 4 - Treinamento da RNA com filtro mediano de ordem 400

Nas condições de 1 a 6 foram empregadas 3 situações de desequilíbrio de tensão:

- alimentação normal (sem desequilíbrio de tensão);
- subtensão, no intervalo de -1% a -10%, com variações de 1%;
- condição de falta de fase.

Nas condições de 7 a 12 utilizou-se apenas situações de sobretensão, no intervalo de +1% a +10%, com variações de 1%.

Condição 1

A Figura 5 ilustra os resultados de treinamento da RNA para a rugosidade superficial (R_a) e a Figura 6 mostra o erro relativo médio (ERM) para as amostras de nº 1 a 12, para as seguintes condições de usinagem: velocidade de corte $V_c = 398,982$ m/min., avanço $f = 0,074$ mm/volta e a profundidade de usinagem (a_p) = 0,5 mm.




Figura 5. Resultado de treinamento da RNA para 1ª condição de desequilíbrio

Observa-se pela Figura 5 que a rugosidade estimada pela RNA apresentou resultados compatíveis com as rugosidades aferidas para todas as condições de alimentação da máquina-ferramenta. A maior rugosidade foi observada na condição de falta de fase, cujo valor é de $1,17 \mu\text{m}$, e a menor rugosidade foi de $0,76 \mu\text{m}$, verificada na condição de subtensão de -4%.

Estes resultados são pequenos, quando comparados à faixa de valores possíveis de ser alcançados para o processo de torneamento, que está situado entre $0,2$ a $12,5 \mu\text{m}$. Conforme apresentado na Figura 6, o maior erro obtido foi na amostra de nº 9 e o menor na amostra de nº 12.




Figura 6. Resultado do ERM para 1ª condição de desequilíbrio

A tabela 4 apresenta os erros relativos médios (ERM) máximo e mínimo entre as rugosidades aferida e estimada pela RNA proposta, para todas as 12 condições de ensaios.

Tabela 4. Erro relativo médio máximo e mínimo entre as rugosidades aferida e estimada pela RNA

Condição	V_c (m/min.)	f (mm/volta)	ERM(%)	
			Máximo	Mínimo
1	398,982	0,074	$5,715 \cdot 10^{-4}$	$9,929 \cdot 10^{-5}$
2	398,982	0,150	$6,208 \cdot 10^{-4}$	$1,202 \cdot 10^{-5}$
3	398,982	0,251	$1,618 \cdot 10^{-3}$	$4,021 \cdot 10^{-5}$
4	199,500	0,074	$3,569 \cdot 10^{-4}$	$6,597 \cdot 10^{-5}$
5	199,500	0,150	$4,435 \cdot 10^{-4}$	$1,242 \cdot 10^{-4}$
6	199,500	0,251	$5,802 \cdot 10^{-4}$	$8,247 \cdot 10^{-5}$
7	398,982	0,074	$5,992 \cdot 10^{-4}$	$9,804 \cdot 10^{-5}$
8	398,982	0,150	$1,754 \cdot 10^{-3}$	$5,639 \cdot 10^{-5}$
9	398,982	0,251	$2,049 \cdot 10^{-4}$	$2,359 \cdot 10^{-5}$
10	199,500	0,074	$9,567 \cdot 10^{-4}$	$1,245 \cdot 10^{-5}$
11	199,500	0,150	$9,052 \cdot 10^{-4}$	$5,757 \cdot 10^{-5}$
12	199,500	0,251	$2,208 \cdot 10^{-4}$	$5,381 \cdot 10^{-5}$

Considerando os problemas associados à variação da tensão da rede elétrica, os valores obtidos do erro relativo médio foram reduzidos em todas as condições de ensaio, o que atesta a capacidade de generalização da rede neural proposta e a sua aplicabilidade como preditor de rugosidade de peças usinadas, baseado exclusivamente em medidas da corrente eficaz da alimentação do motor de indução trifásico que aciona a máquina-ferramenta. Para as condições de usinagem empregadas, verificou-se que os valores de rugosidade aumentaram com o aumento do avanço da ferramenta.

Os resultados obtidos permitem afirmar que a qualidade de energia exerce influência sobre os valores de rugosidade obtidos em um processo de torneamento, uma vez que, para as mesmas condições de usinagem, a rugosidade obtida em condições sem desequilíbrios de tensão (condição normal) resultaram diferentes daquelas obtidas em condições de desequilíbrio de tensão; ou seja, nas condições de falta de fase, de sobretensão ou de subtensão.

Para as condições de ensaios empregadas neste trabalho e considerando os resultados obtidos, pode-se dizer que, caso o processo considerado seja um torneamento de desbaste, a qualidade de energia não será decisiva no acabamento superficial do componente usinado. Segundo Klocke (2011) o campo usual de variação da rugosidade superficial (R_a) nestas operações varia de $3,2 \mu\text{m}$ a $12,5 \mu\text{m}$, intervalo muito maior do que a máxima diferença de rugosidade (entre os valores máximos e mínimos) verificada entre todos os ensaios, a qual foi de $0,53 \mu\text{m}$ para a 6ª condição de ensaios.

Por outro lado, caso o torneamento seja de acabamento, a variação da qualidade de energia poderá ser significativa para a obtenção dos valores de rugosidade, pois, de acordo com Klocke (2011), os menores níveis de rugosidade neste tipo de operação podem variar de $0,2 \mu\text{m}$ a $0,4 \mu\text{m}$ (R_a), intervalo menor do que a máxima diferença de rugosidade verificada nos ensaios ($0,53 \mu\text{m}$).

Em resumo, os resultados obtidos nos 12 casos estudados indicam que a rede *Perceptron* Multicamadas é capaz de prever a rugosidade superficial para a faixa de variação de tensão de -10% a +10%, inclusive para falta de fase, imposta em uma fase do MIT de acionamento da máquina-ferramenta (torno mecânico).

5 Conclusão

À partir dos resultados obtidos neste trabalho pode-se concluir que: os resultados de simulação, conforme a Figura 2 mostra que a rugosidade estimada pela RNA foram próximas à rugosidade de referência (aferida), indicando uma elevada capacidade de representação da rugosidade obtida pela rede neural artificial frente às variáveis de entrada (correntes RMS das fases A, B e C), apresentando Erro Relativo Médio da ordem de 0,01% (conforme Tabela 2).

Na parte experimental, considerando os problemas associados à variação da tensão da rede elétrica, a rede neural artificial (RNA) proposta foi capaz de estimar os valores de rugosidade obtidos em um processo de torneamento a partir dos valores de corrente eficaz que alimentam o motor de indução trifásico de acionamento da máquina-ferramenta.

Os valores estimados de rugosidade pela rede neural artificial (RNA) apresentaram erros muito pequenos em relação aos valores de referência, o que atesta a sua capacidade de generalização, possibilitando o seu uso como preditor de padrões de rugosidade de peças obtidas em processos de usinagem para uma gama de condições de corte, podendo ser utilizado no planejamento e controle de qualidade.

O maior erro relativo médio entre os valores de rugosidade aferida e os estimados pela RNA para todas as condições de ensaio foi de 0,001754% (condição 8) para sobretensão de 1%. Os maiores picos de erro perceptíveis foram observados para condição 3 sem desequilíbrio de tensão, ou seja, equilibrado, provavelmente devido às vibrações presentes durante o experimento. Entretanto, o erro relativo médio foi de 0,001618%.

Não foi possível estabelecer uma tendência geral de comportamento dos valores de rugosidade em função dos desequilíbrios da tensão de alimentação da máquina-ferramenta.

Agradecimentos

Ao Cipeca – Centro Integrado de Pesquisa em Controle e Automação da Universidade Tecnológica Federal (UTFPR) – Câmpus de Cornélio Procópio; à Fundação Araucária (Processo N^o 06/56093-3) e ao Cnpq (Processo N^o 474290/2008-5, N^o 473576/2011-2 e N^o 552269/2011-5).

Referências Bibliográficas

- Abhang, L.B.; Hameedullah, M. Modeling and Analysis of Surface Roughness in Steel Turning Using Regression and Neural Networks. International Conference On Advances In Engineering, Science And Management (ICAESM-2012) March 30,31. IEE, 2012.
- Asiltürk, İlhan; Ünüvar, Ali. Development of a Neural Network Based Surface Roughness Prediction System Using Cutting Parameters and an Accelerometer in Turning. IEEE, 2010.
- Bernardo, P. G.; Vosniakos G.C. Predicting surface roughness in machining: a review, International Journal of Machine Tools & Manufacture, vol. 43, pp. 833-844, 2003.
- DeGarmo, Paul, Ernest. Materials and processes in manufacturing, Tenth Edition. United. States of. América: John Wiley & Sons, Inc, 2008.
- Ferraresi, D. Usinagem dos metais. São Paulo, Edgard Blücher, 1977.
- Fitzgerald, A. E.; Kingsley, Jr. C.; Umans, Stephen D. Máquinas Elétricas, 6ª Ed., Porto Alegre: Bookman, 2006.
- Haykin, S. Neural Networks and Learning Machines, Prentice Hall, 2008.
- Huang, Jiming; Zhang, Wenbin; Chen Rongqiang. Selection and Processing of Surface Roughness for Mechanical Parts. International Conference on Electronic & Mechanical Engineering and Information Technoloy. IEEE, 2011.
- Karpat, Y.; Özel, T. (2005). Hard turning optimization using neural network modeling and swarm intelligence, Transactions of NAMRI/SME, vol XXXIII, pp. 179-186.
- Karpat, Y.; Özel, T. (2006a). Swarm-Intelligent Neural Network System (SINNS) based multi-objective optimization of hard turning, Transactions of NAMRI/SME, vol XXXIV, pp. 9-16.
- Karpat, Y.; Özel, T. (2006b). Multi-objective optimization for turning processes using neural network modeling and dynamic-neighborhood particle swarm optimization, International Journal of Advanced Manufacturing Technology, DOI 10.1007/s00170-006-0719-8 (in print).
- Klocke, Fritz. Manufacturing Processes 1 – Cutting, RWTH edition, Springer – Verlag, Berlin – Germany, 2011.
- Krause, Paul C.; Wasynczuk, Oleg; Sudhoff, Scott D. Analysis of electric machinery and drive systems. 2nd ed. New York: IEEE Press, c2002. Xvi, pp. 605 - 613. (IEEE press power engineering series) ISBN 0-471-14326-X.
- Krishnan, Ramu. Electric motor drives: modeling, analysis and control, Prentice Hall, Inc. New Jersey, USA, 2001.
- Lacalle, Norberto Lopez de; Mentxaka, Aitzol Lamikiz. Machine Tools for High Performance Machining, Springer 2nd Printing., 2009, XXII, 442 p. 300 illus.
- Makadia, Ashvin J.; Nanavati, J.I. Optimisation of machining parameters for turning operations based on response surface methodology. ScienceDirect - Measurement 46 (2013) 1521–1529. Elsevier, 2013.
- Ong, Chee-M. Dynamic Simulation of Electric Machinery Using Matlab/Simulink, Printice Hall Inc, 1997.
- Özel, Tugrul; Karpat, Yigit. Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks, International Journal of Machine Tools & Manufacture, Vol. 45, pp. 467-479, 2005.
- Özel, Tugrul; Correia, A. Esteves; Davim, J. Paulo. Neural network process modelling for turning of steel parts using conventional and wiper inserts, International Journal Materials and Product Technology, Vol. 35, Nos 1/2, 2009.
- Pontes, Fabricio J.; Ferreira, João R.; Silva, Messias B.; Paiva, Anderson P.; Balestrassi, Pedro Paulo. Artificial neural networks for machining processes surface roughness modeling, Int J Adv Manuf Technol (2010) 49:879-902.
- Souza, André João de. Apostila – Processos de fabricação por usinagem (Parte 1), 2011. Universidade Federal do Rio Grande do Sul – Escola de Engenharia, 2011.
- Upadhyay, Vikas, Jain, P.K.; Mehta, N.K. In-process prediction of surface roughness in turning of Ti–6Al–4V alloy using cutting parameters and vibration signals In-process prediction of surface roughness in turning of Ti–6Al–4V alloy using cutting parameters and vibration signals. ScienceDirect - Measurement 46 (2013) 154–160. Elsevier, 2013.
- Zain, Azlan Mohd; Haron, Habibollah; Sharif, Safian. Review of ANN Technique for Modeling Surface Roughness Performance Measure in Machining Process, 2009 Third Asia International Conference on Modelling & Simulation, 2009.