

# APLICAÇÃO DE REDES NEURAIIS ARTIFICIAIS NA PREDIÇÃO DE PEÇAS RETIFICADAS

## **Carlos Eduardo Dorigatti Cruz**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Departamento de Engenharia Mecânica, CEP 17033-360 Bauru – SP, [cedc@feb.unesp.br](mailto:cedc@feb.unesp.br)

## **Wallace C. F. de Paula**

Faculdade de Ciências - Pós-graduação em Ciência e Tecnologia de Materiais – UNESP - Campus de Bauru, CEP 17033-360 Bauru – SP, [wallacedp@uol.com.br](mailto:wallacedp@uol.com.br)

## **Paulo Roberto de Aguiar**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Departamento de Elétrica, CEP 17033-360 Bauru – SP, [aguiarpr@feb.unesp.br](mailto:aguiarpr@feb.unesp.br)

## **Eduardo Carlos Bianchi**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Departamento de Engenharia Mecânica, CEP 17033-360 Bauru – SP, [bianchi@feb.unesp.br](mailto:bianchi@feb.unesp.br)

## **André Jordan Botaro de Lima**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Departamento de Engenharia Elétrica, CEP 17033-360 Bauru – SP, [jordan@feb.unesp.br](mailto:jordan@feb.unesp.br)

**Resumo:** *Atualmente vários sistemas têm sido testados buscando obter um método aplicável e seguro para automação e controle da retificação. Este trabalho teve por objetivo prever a rugosidade de peças retificadas de aço ABNT 1020. Sinais de emissão acústica e potência do motor elétrico que aciona o rebolo foram monitorados, e após tratamento estatístico, formaram três conjuntos de dados que serviram como entradas ao treinamento e validação de uma rede neural artificial. A rede com seu sistema lógico matemático interpretava os sinais predizendo a rugosidade da peça. Os resultados advindos das redes neurais foram comparados com os valores de rugosidade medida e mostraram elevada eficiência do sistema comprovando sua aplicabilidade no monitoramento e controle do processo de retificação. Uma comparação entre a eficiência dos três conjuntos de entrada também foi realizada.*

**Palavras-chave:** *Acabamento Superficial, retificação plana, rugosidade, redes neurais artificiais.*

## **1. INTRODUÇÃO**

O processo de retificação é comumente usado na produção de componentes que exigem alta qualidade superficial e apertadas tolerâncias.

Segundo Wang et al.<sup>(1)</sup>, apesar de sua importância e popularidade em campos industriais, a retificação ainda se apresenta como um dos processos de fabricação de maior dificuldade de entendimento, onde pouco se sabe sobre o controle de seus resultados.

Haussi & Diniz<sup>(2)</sup> relatam que, além de muito usada, a retificação ainda tem sua importância acrescida por se tratar de um processo de acabamento, normalmente utilizada no final de linhas de produção, onde o valor agregado à manufatura é bastante elevado e descartes são bastante caros.

Desta forma, segundo Hundt et al.<sup>(3)</sup> e Aguiar et al.<sup>(4)</sup> o monitoramento do processo de retificação torna-se obrigatório, sobretudo para aumentar a competitividade das empresas que se utilizam deste processo em suas linhas de produção. Para realizar este controle, o sensoriamento de

sinais de emissão acústica (EA) vem ganhando cada vez maior popularidade e uso, por não serem considerados caros e terem simples montagem. No entanto, técnicas confiáveis para extrair informações do processo ainda necessitam ser desenvolvidas e ou aprimoradas.

Sinais de Potência do motor elétrico também já foram largamente usados em pesquisas para se entender melhor o processo bem como realizar o controle da retificação. O monitoramento deste sinal é feito tanto pela aquisição da corrente elétrica que alimenta o motor quanto pelo produto resultante da aquisição dos sinais de tensão e corrente elétricas que fornecem a potência elétrica consumida. Desta forma, segundo Aguiar et al.<sup>(4)</sup>, uma estimativa do valor da força de corte pode ser facilmente obtida conhecendo-se o modelo do motor elétrico.

Aguiar et al.<sup>(4,7)</sup>, Dotto et al.<sup>(5)</sup> e Kwak & Ha<sup>(6)</sup> mostraram em seus trabalhos sistemas eficientes utilizando sinais de EA e potência do motor elétrico no monitoramento de parâmetros e reconhecimento de fenômenos do processo de retificação.

De acordo com Wang et al.<sup>(1,8)</sup>, Dotto et al.<sup>(5)</sup>, Kwak & Ha<sup>(6)</sup> e Aguiar et al.<sup>(7)</sup>, as redes neurais artificiais atraíram especial atenção dos pesquisadores da retificação por conterem funções de aprendizado, interpolação e reconhecimento e classificação de padrões. Em seus trabalhos, é possível encontrar diferentes aplicações bem sucedidas destas técnicas.

Das variáveis de controle do processo de retificação, a rugosidade é, segundo Wang et al.<sup>(1)</sup>, um dos mais importantes parâmetros para determinar a qualidade do componente. Na prática, monitorar e controlar a qualidade é uma difícil tarefa, pois diversas variáveis afetam-na, e dentre essas, muitas são de comportamento não linear, indetermináveis ou de difícil quantificação, influenciando assim a precisão do controle. Esses fatores reforçam a idéia de que os resultados da retificação só podem ser representados e entendidos através de experimentos laboratoriais, além de demonstrarem que o uso de sistemas inteligentes torna-se inevitável.

Este trabalho teve por objetivo usar redes neurais artificiais a fim de se obter de uma ferramenta capaz de prever os valores de rugosidade de peças de aço ABNT 1020, retificadas em uma máquina retificadora plana. Para tanto, sinais de emissão acústica e potência do motor elétrico, medidas no momento do corte, foram usados e após constituírem grupos de estatísticas serviram de alimentação à rede neural. Os valores preditos pela rede usando diferentes estatísticas foram comparados à rugosidade medida na peça, permitindo checar a eficiência do sistema e possibilitando uma comparação entre as estatísticas usadas.

## 2. REVISÃO TEÓRICA

De acordo com Lezanski & Rafalowicz<sup>(9)</sup>, a retificação é um dos mais complexos processos da fabricação. A física do sistema é afetada por diversos fatores que produzem resultados dificilmente parametrizados. Dentre esses, o que mais se destaca, é que, a capacidade e a forma de corte do rebolo mudam consideravelmente durante a execução do processo. Com isso, na prática, a retificação é realizada com parâmetros que são seguros à obtenção dos resultados desejados, porém não otimizados. Acrescido a isso, com este difícil controle, a qualidade das peças acabadas depende da experiência do operador da máquina.

Segundo Brinksmeier et al.<sup>(10)</sup>, o resultado do processo de retificação pode ser subdividido dentro de características que se referem à geometria da peça e sua integridade superficial. Relativos à geometria da peça, pode-se destacar fatores como dimensão, forma, regularidade no acabamento e ondulações, como essenciais resultados macroscópicos do processo, enquanto que a rugosidade pode ser considerada o mais importante resultado microscópico do processo. O estado de integridade superficial da peça pode ser descrito pelas tensões residuais, dureza e estrutura do material ao fim do processo.

De acordo com Bhushan<sup>(11)</sup>, independente do processo de manufatura utilizado, a superfície da peça conterá as irregularidades e desvios supracitadas oriundos de sua manufatura. Estas irregularidades podem ser escalonadas em diferentes ordens de imperfeições de forma que vão de desvios macroscópicos até os níveis referentes ao distanciamento dos átomos na cadeia atômica. Em

aplicações tecnológicas, ambos os desvios, tanto macro quanto microscópicos têm elevada importância.

A figura 1 mostra uma descrição geral da topologia de superfícies sólidas. Superfícies com texturas determinísticas podem ser estudadas com relativa simplicidade, através de métodos analíticos ou empíricos, que produzem boas caracterizações ao entendimento do processo. Contudo, a superfície de grande parte das peças de engenharia tem características aleatórias, tanto isotrópica quanto anisotrópica, Gaussiana como não Gaussiana, dependendo mais da natureza do seu processo de fabricação.

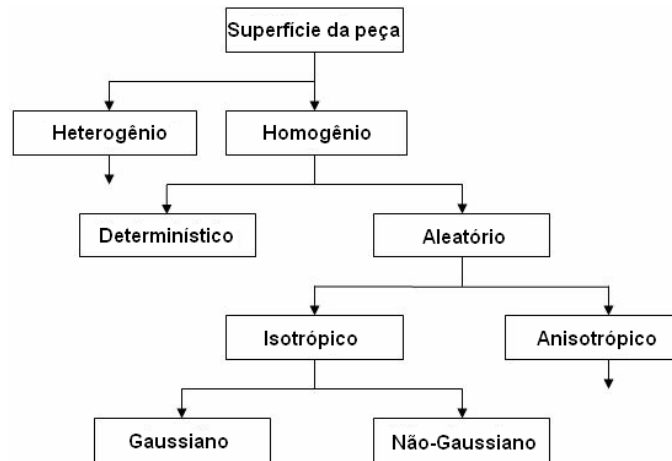


Figura 1. Tipologia de superfícies, segundo Bhushan [11]

De acordo com Bhushan<sup>(11)</sup>, superfícies formadas por um acúmulo de processos (como peening, eletro-erosão e lapidação), nos quais a forma final de cada região resulta do acúmulo de inúmeros processos discretos, aleatórios e de características locais, irá conter um resultado de forma Gaussiana, como consequência direta do teorema do Limite Central provindo de teorias estatísticas. Processos de ferramentas de corte com geometria definida em um único ponto de corte (como o torneamento) e com diversas arestas de corte (como a retificação e o fresamento) geralmente, conduzem à formação de superfícies anisotrópicas e não Gaussiana. A distribuição Gaussiana ou normal define-se como um dos marcos da classificação das superfícies.

Hecker & Liang<sup>(12)</sup> relatam que a rugosidade destaca-se como um dos mais usados parâmetros de qualificação da topografia de superfícies retificadas. Normalmente é definido pelos valores de rugosidade média aritmética,  $R_a$ , rugosidade média quadrática,  $R_q$ , e máximo pico ou vale de rugosidade,  $R_t$ . Além do tipo de medida realizado, a direção na qual ela é feita também influi no seu valor. Geralmente, a rugosidade medida na direção perpendicular ao corte tem maior valor que da linha longitudinal.

De acordo com Kwak et al.<sup>(13)</sup> a rugosidade da peça retificada depende de uma complexa interação entre tipo e topografia da ferramenta, parâmetros de corte usados e interações tribológicas entre pontos de corte abrasivo e peça.

De acordo com Dornfeld<sup>(14)</sup>, muitos sistemas para monitorar a condição da ferramenta e os parâmetros de corte por ela apresentados foram propostos e analisados nas últimas duas décadas. Sinais de emissão acústica gerado durante o corte foram considerados como uma ferramenta sensível para detecção e compreensão de fenômenos, como remoção do cavaco, os mecanismos de escorregamento entre peça e ferramenta, as deformações plásticas e transformações de fase ocorridas no material da peça, e a detecção de micro fissuras, fraturas e trincas. O sensoriamento do sinal de emissão acústica aproveita as informações contidas em ondas elásticas geradas na deformação do material.

Mas não apenas a utilização destes sinais é importante ao controle de um processo. Redes neurais artificiais também atraíram o interesse de diversos pesquisadores envolvidos no controle da retificação, sobretudo os que pretendiam usá-la para a predição da rugosidade. Os trabalhos de

Wang et al.<sup>(1)</sup>, Aguiar et al.<sup>(7)</sup>, Kwak et al.<sup>(13)</sup> e Fredj et al.<sup>(15)</sup>, são alguns dos exemplos que podem ser citados.

As redes neurais artificiais foram estudadas durante vários anos na busca de alcançar algumas características apresentadas pelo cérebro humano, em variados campos, como na linguagem, reconhecimento de imagem e classificação de padrões. Estas redes neurais são compostas por inúmeros elementos computacionais, com características de transmissões de dados de forma não linear e operando em paralelo.

Segundo Kwak & Há<sup>(6)</sup>, devido à variada constituição que as redes neurais podem apresentar, elas são capazes de interpretar diferentes fenômenos e aprender com as características de cada um. Ainda segundo os autores, esta capacidade de aprendizado é fortemente influenciada pela forma de treinamento empregado e uma precisa definição sobre as dificuldades de aprendizado apresentada por cada estrutura é de difícil compreensão, pois está baseada na determinação dos inúmeros pesos de cada conexão neural.

O que distingue este trabalho de outros é o fato de que diferentes estatísticas foram usadas no tratamento dos sinais de emissão acústica e potência elétrica, coletados a uma elevada taxa de aquisição durante o processo.

### 3. MATERIAL E MÉTODOS.

#### 3.1 Banco de Ensaio e Parâmetros de Usinagem

Barras laminadas de aço ABNT 1020, retificadas em formato de prisma, com dimensões de 150,0 mm de comprimento, 12,7 mm de largura e 43,0 mm de altura, foram usadas como corpo de prova.

Para realização dos ensaios foi utilizada uma máquina retificadora, da marca Sulmêcnica, modelo RAPH – 1055, equipada com um rebolo de óxido de alumínio da marca Norton, modelo ART-FE-38A80PVH. Para leitura dos sinais foi usado um sensor de emissão acústica do fabricante Sensus, modelo DM-42, fixo à mesa da máquina e acoplado a um módulo processador de sinais, e um módulo para a medição da potência elétrica do motor elétrico que aciona o rebolo. Este módulo mede a tensão e corrente elétricas do motor através de sensores de efeito Hall, e em seguida esses sinais são multiplicados por um circuito integrado, entregando para a placa de aquisição um sinal de tensão elétrica proporcional à potência elétrica consumida pelo motor.

Os sinais adquiridos foram enviados a uma placa interna ao computador, inicializada através de um programa de aquisição construído com as ferramentas do *software* LabVIEW. A figura 2 mostra um esquema representativo do banco de ensaios.

Os ensaios foram realizados para 15 diferentes profundidades de corte, tendo 5µm como menor valor e 50µm como maior profundidade de corte testada. Parâmetros de dressagem do rebolo, lubrificação e velocidade tangencial de corte foram controlados de tal maneira a garantir que sempre se fosse respeitada a mesma condição de usinagem. A velocidade da mesa da máquina retificadora foi definida  $V_w=0,043\text{m/s}$ , e a velocidade de rotação do rebolo variada e aumentada de acordo com sua perda diametral. O grau de recobrimento de dressagem foi mantido igual a 1 e estabeleceu-se a concentração do fluido de corte igual a 4% em volume de lubrificante.

Para cada condição de profundidade de corte analisada foram feitos 3 ensaios, buscando-se obter repetibilidade de dados.

Os ensaios constituíam-se de uma passada única do rebolo sobre todo o comprimento da peça com a profundidade de corte analisada. Os sinais de EA e potência do motor elétrico eram medidos em tempo real a uma taxa de dois milhões e meio de pontos por segundo, para cada sinal, e então registrados no computador, fornecendo assim as futuras entradas para o treinamento das redes neurais.




Figura 2 – Representação Esquemática do Banco de Ensaios.

### 3.2. Medidas de Rugosidade

Concluídos os ensaios de usinagem foram realizadas medidas de rugosidade, com o auxílio de um rugosímetro portátil, da marca Taylor Hobson, modelo Surtronic 3+, nas regiões usinadas, com a tomada de 15 linhas ao longo do comprimento da peça, mostradas na figura 3. O comprimento de amostragem foi definido em 8 mm e a rugosidade média aritmética ( $R_a$ ) definida como parâmetro para medição.




Figura 3 - Linhas mostrando as 15 divisões feitas na peça, sobre as quais foi medida a rugosidade

Estes dados serviram para alimentar a rede neural e possibilitaram a conferência de grandezas e a eficiência do sistema na predição da rugosidade.

### 3.3. Parâmetros estatísticos usados nas redes neurais artificiais

Diversos parâmetros usados no monitoramento de falhas em processos de retificação foram estudados. Dentre eles, dois importantes parâmetros estudados por Aguiar et al.<sup>(4)</sup> e, Dotto et al.<sup>(5)</sup> foram: o parâmetro DPO e o DPKS. O parâmetro DPO é definido como o desvio padrão do valor médio quadrático da emissão acústica multiplicado pelo valor máximo de potência adquirido durante a passada ou ciclo de retificação. O DPKS é a soma da diferença entre a potência de corte e o desvio padrão da mesma, ambos elevados a quarta potência e então multiplicados pelo desvio padrão do sinal RMS de emissão acústica para cada ciclo de retificação ou passada. As estatísticas DPO e DPKS são mostradas respectivamente nas equações 1 e 2.

$$DPO = std(EA) * \max(POT) \quad (1)$$

onde:  $std(EA)$  é o desvio padrão do sinal de emissão acústica por passada e  $\max(POT)$  é a potência máxima por passada e;

$$DPKS = \left\{ \sum_{i=1}^{i=m} [POT(i) - std(POT)]^4 \right\} * std(EA) \quad (2)$$

onde:  $i$  é o índice da potência que varia de 1 até  $m$ ;  $m$  é o número de pontos da passada;  $POT(i)$  é o valor instantâneo da potência;  $std(POT)$  é o desvio padrão da potência na passada e;  $std(EA)$  é o desvio padrão da emissão acústica RMS da passada.

Por meio dos sinais de EA e potência de corte adquiridos durante o processo foram calculados os valores de DPO e DPKS, e esses valores juntos a outros ou isolados foram usados como parâmetros que constituíam as entradas das redes neurais artificiais.

### 3.4. Redes neurais artificiais e conjuntos de treinamento.

Segundo Aguiar et al.<sup>(7)</sup> redes neurais artificiais podem ser resumidas em modelos computacionais de funcionamento análogo ao cérebro humano para determinadas características, entre elas, a capacidade de aprendizado. Elas são compostas de inúmeros elementos computacionais não lineares que operam de modo paralelo.

De acordo Kwak & Há<sup>(6)</sup>, a variada constituição que as redes neurais podem apresentar as tornam capazes de interpretar diferentes fenômenos e aprender com as características de cada um. Ainda segundo os autores, esta capacidade de aprendizado é fortemente influenciada pela forma de treinamento empregado, e uma precisa definição sobre as dificuldades de aprendizado apresentada por cada estrutura é de difícil compreensão, pois está baseada na determinação dos inúmeros pesos de cada conexão neural.

Para a composição da rede neural utilizada neste trabalho, foi utilizado o algoritmo *Back-Propagation* que é um dos modelos de aprendizado disponíveis. Após diversos testes com diferentes números de camadas e elementos, foi adotada uma rede composta por três camadas ocultas, cada qual contendo 60, 40 e 20 neurônios respectivamente da primeira a última camada.

Outros parâmetros determinados como mais adequados e utilizados na rede são descritos a seguir: funções de transferência do tipo tangente sigmóide para as camadas ocultas; funções de ativação linear para a última camada; algoritmo de treinamento *Downward Gradient*, número máximo de épocas igual a 10000 ou erro médio quadrático de  $10^{-5}$ ; taxa de aprendizagem de 0,3; e momento igual a 0,4. Ainda vale ressaltar que todos os valores usados na rede foram normalizados. A Tabela 1 mostra os três conjuntos de entradas utilizados para alimentar as redes neurais neste trabalho.

Tabela 1 – Composição dos conjuntos de entrada da rede neural

Conjunto N <sup>o</sup>	Composição
1	E.A., Potência Elétrica e Profundidade de Corte
2	E.A., Potência Elétrica, DPO, DPKS e Profundidade de Corte
3	DPO e Profundidade de Corte.

## 4. RESULTADOS E DISCUSSÃO

As medições da rugosidade demonstram que houve um acréscimo das grandezas medidas com o aumento da profundidade de corte, sentida significativamente após a profundidade de corte de 35 $\mu$ m, onde foi detectado queima das peças de serviço. Para ilustrar este crescimento da rugosidade, a figura 4 mostra o valor médio, dado em micrometros, calculado para cada profundidade de corte. Este valor médio refere-se a média dos 15 pontos medidos de rugosidade ao longo da peça para cada condição de usinagem utilizada e três repetições.

Por englobar uma média da rugosidade ao longo de toda a peça, nota-se um elevado desvio padrão nos resultados, mais facilmente visível nas condições de maiores profundidades de corte.

Este fator é explicável pela diferença de valores de rugosidade ao longo do comprimento das peças, sobretudo nos ensaios onde houve queima de determinada região da peça de serviço, havendo grande diferença entre a rugosidade da região que apresentava queima em relação à região que não apresentava.

É importante lembrar que, a figura 4 foi construída apenas para fácil visualização do comportamento da rugosidade em relação à profundidade de corte do ensaio, visto que, para a utilização no treinamento e validação da rede neural foi usada a rugosidade de cada região medida e não as médias calculadas para construção desta figura.




Figura 4 – Valores Médios de Rugosidade ( $R_a$ ) para as 15 profundidades de corte avaliadas

Dos ensaios foram extraídos vetores de EA e Potência de corte. Após cada ensaio, foi obtido o valor médio quadrático do sinal de emissão acústica e realizada a filtragem para ambos os sinais, e assim checar se cada ensaio tinha sido feito com êxito.

Estes valores, aplicados a rede, após o treinamento, forneceram valores de rugosidade preditos, que permitiram a análise da eficiência do sistema. A quantificação dos erros foi feita ponto a ponto através do cálculo do módulo da diferença entre a rugosidade medida com o rugosímetro e o valor fornecido pela rede, em cada um dos 15 pontos de rugosidade de cada corpo de prova.

A tabela 2 mostra os valores dos erros médios entre todos os pontos e entre as três repetibilidades de cada uma das profundidades de corte estudada.

Tabela 2 – Média dos valores dos erros médios de cada profundidade de corte estudada

Profundidade de corte, $\mu\text{m}$	Erro médio do conjunto de entrada, $\mu\text{m}$			Profundidade de corte, $\mu\text{m}$	Erro médio do conjunto de entrada, $\mu\text{m}$		
	1	2	3		1	2	3
5	0,158439	0,231852	0,17608	25	0,357093	0,113761	0,047498
7,5	0,123242	0,099865	0,059965	27,5	0,107012	0,110796	0,134719
10	0,067682	0,049425	0,043206	30	0,141383	0,162491	0,083208
12,5	0,067025	0,051443	0,033784	35	0,496706	0,288377	0,091024
15	0,058053	0,051422	0,027645	40	1,441813	0,502519	0,052033
17,5	0,080372	0,07547	0,045735	45	1,638409	0,434839	0,075053
20	0,280994	0,10077	0,088386	50	2,006648	0,462763	0,341236
22,5	0,313688	0,163564	0,059238				

Da tabela 2 nota-se que o conjunto de entrada 1 apresentou erros bastante elevados para as maiores profundidades de corte estudadas, ultrapassando a casa de  $10^{-1}\mu\text{m}$ , nas três últimas condições. Como dito anteriormente, uma análise de integridade feita nos corpos de prova demonstrou que a partir da profundidade de corte de  $35\mu\text{m}$  iniciou-se a queima nas peças de serviço. Atribui-se a este fator a possibilidade de maiores erros para este conjunto de entrada. Este

erro, contudo, pode demonstrar sensibilidade maior destes sinais a outros parâmetros de controle do processo, como a queima da peça de serviço.

O conjunto de entrada 2 também apresentou maiores erros nas três condições finais, não tendo contudo, ultrapassado em média a escala de  $10^{-1}\mu\text{m}$ .

O conjunto de entrada 1 apresentou os melhores resultados médios, sendo que em apenas três das quinze profundidades de corte apresentou erros acima da ordem de  $10^{-2}\mu\text{m}$ , e estes não ultrapassaram a escala de  $10^{-1}\mu\text{m}$ .

Baseados nestes dados, as diferenças entre a medida real e as saídas da rede foram classificadas em 3 grupos distintos. Como o rugosímetro utilizado nas medidas de rugosidade deste trabalho apresenta duas casas decimais (décimos e centésimos de micra) após a vírgula, e sabe-se que, para este aparelho, a segunda casa decimal trata-se de seu algarismo de incerteza de medida, todos os erros da ordem de  $10^{-2}$  micra ou inferiores foram considerados como acertos da rede na predição da rugosidade.

Esta consideração é reforçada pelas tolerâncias aplicadas ao processo de retificação em campos industriais, que em quase sua totalidade tem o décimo de micra como tolerância especificada às peças retificadas.

No segundo grupo foram colocados erros da ordem de  $10^{-1}$  micra, tidos como não grosseiros, contudo, com mais ressalva ao tipo de componente fabricado, e finalmente nos último grupo estão os erros da ordem de 1 micron, classificados como grosseiros ao processo. A figura 5 mostra, a partir destas considerações, o comportamento dos três conjuntos de entrada e a porcentagem de erros nas categorias estabelecidas de cada um destes conjuntos.




Figura 5. Percentagens de erros e acertos da predição da rede neural artificial para os três conjuntos de estatísticas aplicados s sua entrada

Da análise da figura 5 e dos demais resultados advindos do estudo da saída das redes neurais e sua comparação com os valores de rugosidade medidos pode-se afirmar que:

Dos conjuntos usados no treinamento da rede o que forneceu os melhores valores de saída para quase a totalidade das situações foi o conjunto de entrada 3, composto pela estatística DPO e profundidade de corte. Este conjunto de entrada forneceu cerca de 70% de acertos na predição da rugosidade, analisada ponto a ponto e não apresentou nenhum erro tido como “grosseiro” ao controle do processo de retificação.

O conjunto de entrada 1, composto pelos sinais de EA, potência de corte e profundidade de corte apresentou desempenho satisfatório em grande parte das condições testadas, demonstrando, entretanto erros bastante elevados, principalmente nas condições de maiores profundidades de corte. Nestas condições ocorreu a queima na peça de serviço, o que pode significar uma possível sensibilidade deste conjunto a outros parâmetros além da rugosidade.

O conjunto de entrada 2, composto pela maior parte de sinais (EA Potência, DPO, DPKS e profundidade de corte), também teve desempenho satisfatório, a exemplo do ocorrido com o conjunto de entrada 1. Os valores da predição destes conjuntos alternaram-se, ora melhores ora



piores, na comparação entre um e outro. É importante ressaltar que este conjunto apresentou, para algumas situações, erros mais elevados que os vistos no conjunto de entrada 3, contudo, obteve bom desempenho na análise de erros grosseiros, apresentando apenas 3,1% de pontos com este tipo de erro.

## 5. CONCLUSÕES

A técnica usada neste trabalho para a predição da rugosidade em peças retificadas baseou-se na utilização de sinais providos do sensoriamento e da potência de corte no momento da usinagem.

Baseado nos resultados apresentados nesta pesquisa pode-se concluir que os sinais de emissão acústica e potência do motor elétrico se apresentaram como bons sinais de entrada para as redes neurais quando se pretende prever a rugosidade de peças retificadas, sendo possível a implementação dos mesmos no controle de processos industriais, haja vista a baixa ou nenhuma percentagem de erros grosseiros das saídas da rede.

Dos conjuntos usados na alimentação e treinamento da rede, e para as condições e métodos usados, o conjunto composto apenas pelo sinal DPO e profundidade de corte foi o que apresentou melhores resultados, conseguindo-se cerca de 70% de acerto e nenhum erro grosseiro. Na comparação entre os erros apresentados por cada conjunto, ele foi seguido ora pelo conjunto composto por EA, potência elétrica e profundidade de corte, e ora pelo conjunto acrescido do sinal DPO e DPKS.

## 6. REFERÊNCIAS.

1. J. Z. WANG, L. S. WANG, G. F. LI & G. H. ZHOU, Prediction of surface roughness in cylindrical traverse grinding based on ALS algorithm, *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics*, Guangzhou, 18-21 August 2005, 549-554.
2. A. HASSUI & A. E. DINIZ, Correlating surface roughness and vibration on plunge cylindrical grinding of steel, *International Journal of Machine Tools & Manufacture*, 43, 2003, 855-862.
3. W. HUNDT, F. KUSTER & F. REHSTEINER, Model-based AE monitoring of the grinding process, *Annals of the CIRP*, 45, 1997, 243-247.
4. P. R. AGUIAR, E. C. BIANCHI & J. F. G. OLIVEIRA, A method for burning detection in grinding process using acoustic emission and effective electrical power signal, *CIRP Journal of Manufacturing Systems*, Paris, 31, 2002, 253-257.
5. F. R. L. DOTTO, P. R. AGUIAR, E. C. BIANCHI, P. J. A. SERNI & R. THOMAZELLA, Automatic system for thermal damage detection in manufacturing process with internet monitoring, *Journal of Brazilian Society of Mechanical Science & Engineering*, XXVIII, No. 2, 2006, 153-160.
6. J. S. KWAK & M. K. HA, Neural network approach for diagnosis of grinding operation by acoustic emission and power signals, *Journal of Materials Processing Technology*, 147, 2004, 65-71.
7. P. R. AGUIAR, T. V. FRANÇA & E. C. BIANCHI, Roughness and roundness prediction in grinding, *Proceedings of the 5th CIRP International Seminar on Intelligent Computation in Manufacturing Engineering (CIRP ICME '06)*, 25-28 July, Italy, 2006, 183-188.
8. Z. WANG, P. WILLET, P. R. AGUIAR & J. WEBSTER, Neural network detection of grinding burn from acoustic emission, *International Journal of Machine Tools & Manufacture*, 41, 2001, 283-309.
9. P. Lezanski & J. Rafalowicz, An intelligent monitoring system for cylindrical grinding, *CIRP Ann.*, 42, 1993, 393-396.
10. E. BRINKSMEIERS, H. K. TÖNSHOFF, C. CZENKUSCH & C. HEINZEL, Modelling and optimization of grinding process, *Journal of Intelligent Manufacturing*, 9, 1998, 303-314.
11. B. BHUSHAN, *Modern tribology handbook*, CRC Press LLC, 2001.

12. R. L. HECKER & S. Y. LIANG, Predictive modeling of surface roughness in grinding, *International Journal of Machine Tools & Manufacture*, 43, 2003, 755-761.
13. J. S. KWAK, S. B. SIM & Y. D. JEONG, An analysis of grinding power and surface roughness in external cylindrical grinding of hardened SCM440 steel using the response surface method, *International Journal of Machine Tools & Manufacture*, 46, 2006, 304-312.
14. D. A. DORNFELD, Manufacturing process monitoring and analysis using acoustic emission, *Journal Acoustic Emission*, 4, No. 2/3, 1985, S228-S231.
15. N. B. FREDJ, R. AMAMOU & M. A. REZGUI, Surface roughness prediction based upon experimental design and neural network models, *IEEE SMC*, 2002.
16. S. MALKIN, Grinding technology – theory and applications of machining with abrasives, *Ellis Horwood Limited*, England, 1989.

## **NEURAL NETWORK APPROACH FOR SURFACE ROUGHNESS PREDICTION IN SURFACE GRINDING**

### **Paulo Roberto de Aguiar**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Department of Electrical Engineering, P.O: 17033-360, Bauru – SP, [aguiarpr@feb.unesp.br](mailto:aguiarpr@feb.unesp.br)

### **Carlos Eduardo Dorigatti Cruz**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Department of Mechanical Engineering, P.O: 17033-360, Bauru – SP, [cedc@feb.unesp.br](mailto:cedc@feb.unesp.br)

### **Eduardo Carlos Bianchi**

Universidade Estadual Paulista – UNESP - Campus de Bauru, Department of Mechanical Engineering, PO: 17033-360, Bauru – SP, [bianchi@feb.unesp.br](mailto:bianchi@feb.unesp.br)

**Abstract:** *Several systems are currently tested in order to obtain a feasible and safe method for automation and control of grinding process. This work aims to predict the surface roughness of the parts of SAE 1020 steel ground in a surface grinding machine. Acoustic emission and electrical power signals were acquired by a commercial data acquisition system. The former from a fixed sensor placed near the workpiece and the latter from the electric induction motor that drives the grinding wheel. Both signals were digitally processed through known statistics, which with the depth of cut composed three data sets implemented to the artificial neural networks. The neural network through its mathematical logical system interpreted the signals and successfully predicted the workpiece roughness. The results from the neural networks were compared to the roughness values taken from the workpieces, showing high efficiency and applicability on monitoring and controlling the grinding process. Also, a comparison among the three data sets was carried out.*

**Keywords:** *Surface finishing, surface grinding, surface roughness, neural network, acoustic emission, electric power.*