

MONITORAMENTO DA QUEIMA NO PROCESSO DE RETIFICAÇÃO POR EMISSÃO ACÚSTICA E VIBRAÇÃO

RODOLPHO GODOY¹, CESAR H. R. MARTINS², MARCELO MARCHI¹, PAULO R. AGUIAR², BIANCHI¹, E. C.

1. *Laboratório de Usinagem por Abrasão, Departamento de Engenharia Mecânica, Faculdade de Engenharia, UNESP- Univ. Estadual Paulista*
Av. Eng. Luiz Edmundo Carrijo Coube, 14-01, 17033-660
E-mails: marcelo.marchi@outlook.com, rfg_net@hotmail.com, Bianchi@feb.unesp.br

2. *Laboratório de Aquisição de Dados e Processamento de Sinais, Departamento de Engenharia Elétrica, Faculdade de Engenharia, UNESP- Univ. Estadual Paulista*
Av. Eng. Luiz Edmundo Carrijo Coube, 14-01, 17033-660
E-mails: aguiarpr@feb.unesp.br, cesar.martins@outlook.com

Abstract— The grinding process is widely used in surface finishing of steel parts and corresponds to one of the last steps in the manufacturing process. Thus, it's essential a reliable monitoring of this process. In grinding of metals, the phenomenon of burn is one of the worst faults to be avoided. Therefore, a monitoring system able to identify this phenomenon would be of great importance for the process. Thus, the aim of this work is the monitoring of burn during the grinding process through an intelligent system that uses acoustic emission (AE) and vibration analysis as inputs. Tests were performed on a surface grinding machine, workpiece AISI 1020 and aluminum oxide grinding wheel were used. The acquisition of the vibration signals and AE was done by means of an oscilloscope with a sampling rate of 2MHz. By analyzing the frequency spectra of these signals it was possible to determine the frequency bands that best characterized the phenomenon of burn. These bands were used as inputs to an artificial neural network capable of classifying the surface condition of the part. The results of this study allowed characterizing the surface of the work piece into three groups: No burning, burning and high surface roughness. The selected neural model has produced good results for classifying the three patterns studied.

Keywords— grinding, digital signal processing, monitoring, burning

Resumo— O processo de retificação é amplamente utilizado no acabamento superficial de peças de aço e corresponde a uma das últimas etapas no processo de fabricação. Deste modo, é imprescindível um monitoramento confiável deste processo. Retificando-se metais, o fenômeno da queima é uma das piores avarias a ser evitada. Portanto, um sistema de monitoramento capaz de identificar tal fenômeno, seria de grande importância para o processo. Sendo assim, o objetivo desse trabalho é o monitoramento da queima durante o processo de retificação através de um sistema inteligente que utiliza os sinais de emissão acústica (EA) e vibração como parâmetro de análise. Ensaios foram realizados em uma retificadora plana, corpos-de-prova de aço ABNT 1020 e rebolos de óxidos de alumínio foram utilizados. A aquisição dos sinais de EA e vibração foi feita por meio de um oscilógrafo com taxa de amostragem de 2 MHz. Analisando os espectros de frequência destes sinais foi possível determinar bandas de frequências que melhor caracterizavam o fenômeno da queima. Essas bandas serviram de entradas para uma rede neural artificial capaz de classificar a condição superficial da peça. Os resultados deste estudo possibilitaram caracterizar a superfície da peça em três grupos: Sem queima, com queima e com alta rugosidade. O modelo neural selecionado produziu resultados satisfatórios na classificação dos três padrões em estudo.

Palavras-chave— Processo de retificação, Processamento digital de sinais, Monitoramento, Queima.

1 Introdução

Um dos processos de acabamento mais utilizados na fabricação de componentes mecânicos de precisão é a retificação. Trata-se de um dos processos de menor domínio tecnológico, se comparado aos processos convencionais de usinagem, além de ter a função de solucionar os problemas de qualidade e tempo de toda a sequência de fabricação (Irani, *et al.*, 2005).

De acordo com Liao (2008), a retificação é um dos processos de usinagem mais

complicados, principalmente devido ao fato de que a operação de retificação é realizada por um rebolo retificador, o qual é composto por pequenos e irregulares grãos abrasivos posicionados randomicamente e unidos por um meio. Desta maneira, há uma série de variáveis que dificultam a escolha do parâmetro ideal para realizar uma retificação do modo mais eficiente.

A necessidade de redução efetiva dos gastos, além do aumento da qualidade das peças fabricadas, requer a implementação de sistemas mais inteligentes em ambientes industriais. Por conseguinte, o controle dos danos causados no processo de retificação é de grande interesse de

todas as indústrias dependentes deste processo, levando, assim, a uma diminuição na taxa de refugos e, conseqüentemente, a um baixo custo de produção (Aguiar *et al.*, 2002).

Para Teti *et al.* (2010), na região de corte, há várias variáveis do processo, tais como forças de corte, as vibrações, a emissão acústica, etc, que são influenciadas pelas condições do processo de remoção de material. As variáveis que são interessantes para acompanhar o processo de usinagem podem ser medidas pela aplicação de sensores físicos apropriados. Os sinais detectados por estes sensores estão sujeitos ao condicionamento e processamento digital e analógico, com o objetivo de gerar características de sinal correlacionadas (pelo menos potencialmente) com as condições do processo e/ou estado da ferramenta.

A principal dificuldade em controlar os danos causados no processo de retificação é a falta de um método confiável em fornecer realimentação em tempo real durante o processo. A emissão acústica vem sendo um parâmetro que proporciona cada dia mais evidências e condições de que o processo de retificação pode ser monitorado instantaneamente. Segundo Lee *et al.* (2001), o problema em utilizar a EA para monitoramento do processo está na sensibilidade associada à localização do sensor, uma vez que quanto mais próximo o sensor da região de corte, melhor a leitura dos dados.

Wegener *et al.* (2011) ainda dizem que algo único é o uso da emissão acústica, uma vez que este não dá informação direta do processo de retificação, mas oferece sinais indiretos, a partir dos quais podem ser derivadas as propriedades do processo. Além disso, a emissão acústica está muito mais relacionada com o monitoramento direto do ponto de vista de avaliação do fenômeno em estudo, uma vez que produz os sinais contínuos a partir dos quais os dados relevantes precisam ser extraídos e em seguida, correlacionados com o processo. Segundo Babel *et al.* (2013), devido a superior sensibilidade do sinal de emissão acústica às interações dinâmicas entre o rebolo e a peça de trabalho, este sinal surgiu como uma ferramenta valiosa no monitoramento do processo de retificação.

Teti *et al.* (2010), diz que as vibrações que ocorrem durante o corte de metal podem ser divididas em dois grupos: dependentes e independentemente do processo de corte. Os dois grupos não são mutuamente exclusivos. Vibração independente do corte de metal inclui a vibração forçada causada por outras máquinas ou componentes de máquina, por exemplo, vibração transmitida através de fundações, desequilíbrio de peças rotativas, forças de inércia das peças de movimento alternado e

imprecisões cinemáticas de unidades de acionamento. Vibração dependente do corte em metal pode demonstrar certo número de características em função do processo, por exemplo, corte interrompido. As forças de corte que variam e que ocorrem durante o corte de metal, podem resultar da não homogeneidade e variações das propriedades do material da peça. Condições de acoplamento durante a usinagem desempenham um papel significativo na vibração produzida. A característica de vibração autoexcitada conhecida como *chatter* é o tipo mais conhecido de vibração na usinagem e é prejudicial para o acabamento superficial e vida útil da ferramenta. Chatter ocorre principalmente devido à regeneração da ondulação causada pela interação entre a superfície do material e ferramenta em determinadas frequências de rotação do eixo, e pelo modo de acoplamento em que a vibração relativa entre peça e ferramenta ocorre simultaneamente em duas direções no plano de corte.

Segundo Kim *et al.* (2001), o valor RMS do sinal puro de emissão acústica pode ser expresso pela Equação:

$$EA_{RMS} = \sqrt{\frac{1}{\Delta T} \int_0^{\Delta T} f_{raw}^2(t) dt} \quad (1)$$

Onde ΔT corresponde a constante de tempo de integração, e $f_{raw}(t)$ é o sinal puro de emissão acústica.

Os sinais de emissão acústica e de aceleração possuem cada um suas características próprias, que uma vez extraídas e relacionadas com o fenômeno de estudo podem fornecer dados valiosos para o monitoramento do processo de retificação.

Através do cálculo do sinal RMS de ambos os sinais, e aplicação de outros processamentos, é possível obter informações que alimentem redes neurais artificiais, possibilitando a classificação de acabamentos superficiais de corpos de prova retificados.

1.2 Redes Neurais

Atualmente, as indústrias tem usado cada vez mais a manutenção preditiva para minimizar avarias e seu impacto sobre o desempenho, além de reduzir os intervalos de manutenção e os custos conseqüentes, melhorando, assim, a eficiência de produção e garantindo a segurança. O desenvolvimento de um sistema de manutenção com características inteligentes na detecção de falhas e acúmulo de conhecimento para estruturas mecânicas é uma meta para os pesquisadores, já que um sistema deste tipo seria de grande ajuda às indústrias, à medida que é quase impossível analisar manualmente

dados rapidamente a fim de extrair informações valiosas que permitam tomadas de decisões confiáveis (Ahmadzadeh, 2013).

Rede neural artificial é uma ferramenta de modelagem empírica, que é análogo ao comportamento de estruturas neurais biológicas. As redes neurais artificiais são, basicamente, uma família de arquiteturas massivamente paralelas que resolvem problemas complexos através da colaboração de elementos de computação (Neurônios Artificiais) simples e altamente interconectado (Sadeghiamirshahidi *et al.*, 2013).

De acordo com Marzi (2008), redes neurais têm sido aceitas em aplicações de problemas não lineares, onde encontrar soluções por meio de técnicas convencionais seria muito complexo ou impossível. Exemplos de aplicações incluem robótica, controle e identificação de sistemas. As RNs tem sido aplicadas com sucesso no monitoramento da condição de ferramentas e diagnóstico de falhas. As RNs podem ser definidas como uma rede de elementos de processamento simples. Cada elemento é associado a um peso de ativação, função de saída e regra de ativação. Além disso, são associados com as redes o padrão de conectividade, o peso das conexões, a regra de propagação, e a regra de aprendizagem.

2 Materiais e Métodos

Os ensaios experimentais foram realizados em uma máquina retificadora plana, sendo que cada ensaio resumiu-se a uma única passada do rebolo pelo comprimento do corpo de prova. Após cada ensaio, o rebolo era dressado por um dressador de ponta única de diamante. Na tabela 1, são apresentadas as condições de usinagem de cada ensaio.

Para a coleta dos sinais puros de EA foi utilizado um sensor de emissão acústica da empresa Sensis, com módulo processador de sinais do mesmo fabricante modelo DM-42. Para os sinais de aceleração foi utilizado um sensor fixo modelo 353B03 e um módulo condicionador 482B11, ambos do fabricante PCB Piezotronic. Os dois sinais foram coletados a uma taxa de 2MHz por um oscilógrafo modelo DL850, da Yokogawa.

Para montagem do banco de ensaios foram retificadas peças de aço ABNT 1020, utilizando um rebolo de óxido de alumínio tipo 38A150-LVH da marca Norton. Ambos os sensores foram fixados no suporte da peça e próximos a esta, para obtenção da melhor sensibilidade dos sensores. Observa-se na figura 1 um esquemático da montagem do banco de ensaios.

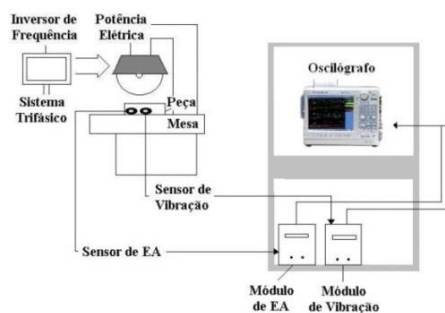


Figura 1. Esquemático do Banco de Ensaio

Depois de retificadas, as peças tiveram suas rugosidades médias (R_a) medidas através de um rugosímetro modelo Surtronic 3+, da marca Taylor Hobbson. Para medição da rugosidade média, a superfície da peça foi dividida em 30 partes igualmente espaçadas e em cada parte mediu-se a rugosidade. Deste modo, foi possível calcular o valor médio de cada secção com seu respectivo desvio padrão, permitindo, deste modo, dados estatisticamente confiáveis.

Foram realizados ao todo 13 ensaios com os seguintes parâmetros:

- Velocidade periférica do Rebolo: 30,78 m/s
- Velocidade da Peça: 0,04 m/s
- Diâmetro do Rebolo: 326,64 mm
- Largura do Rebolo: 24,09 mm
- Dimensões da peça: 152,64 mm x 13,01 mm (Comprimento x Largura)

Tabela 1. Planejamento dos ensaios e Condição da superfície da peça após a Usinagem.

Ensaio	Geometria de Corte	Avanço	Condição da peça
1	Plana	10 μ m	Sem queima
2		20 μ m	Queima
3		30 μ m	Queima
4		40 μ m	Sem queima
5		40 μ m	Sem queima
6		30 μ m	Sem queima
7		20 μ m	Sem queima
8		10 μ m	Sem queima
9		20 μ m	Sem queima
10		30 μ m	Sem queima
11		55 μ m	Rugosidade Alta
12	Rampa	20 μ m-70 μ m	Rugosidade Alta
13		30 μ m-80 μ m	Rugosidade Alta

O conjunto de dados obtidos nos ensaios foi processado por meio do software MATLAB, onde filtros digitais foram aplicados, bem como o algoritmo FFT (Fast Fourier Transform). Com isto, foi realizada a análise do conteúdo

espectral dos sinais de emissão acústica e aceleração, permitindo identificar faixas de frequências que caracterizavam o fenômeno da queima no processo de retificação plana.

A coleta dos dados geraram vetores de 20×10^6 amostras para cada peça usinada. Foram selecionados trechos para cada vetor do sinal puro de emissão acústica e do sinal de aceleração classificados em: sem queima, com queima e com alto valor de rugosidade. Esta classificação foi determinada através da inspeção visual da superfície das peças usinadas e da análise das medidas de rugosidade (valor de Ra).

Para o cálculo da FFT foram considerados trechos das peças usinadas que apresentavam as três situações em estudo, ou seja, trecho com queima, sem queima, e alta rugosidade. O valor RMS de cada sinal (EA e vibração) foi usado como referência para a escolha da posição a partir da qual se desejava obter a FFT. Com o auxílio da função “ginput” do Matlab, obtinha-se a posição correspondente no vetor do sinal puro, e 8195 amostras eram selecionadas a partir desta posição para o cálculo da FFT, com utilização da janela de Hanning. Com esse procedimento, foi possível obter as características de amplitude e frequência para as três condições em estudo tanto para o sinal de EA quanto para o sinal de vibração, conforme Figura 2.

No processo de seleção de bandas, foram considerada para o presente trabalho faixas entre 20kHz a 300kHz para o sinal de EA, e de entre 1kHz a 25kHz para vibração. Assim, foi possível selecionar nove bandas para o sinal de EA e seis bandas para o sinal de vibração, ficando algumas faixas para estudo posterior, como mostra a figura 2.

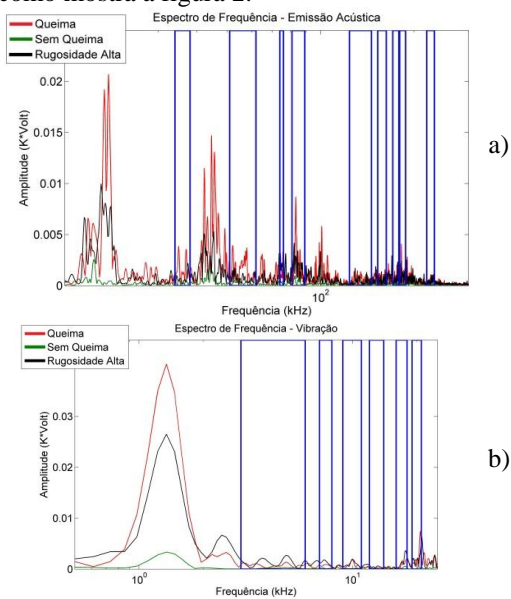


Figura 2. Espectro de Sinal com a seleção de bandas. a) Emissão Acústica b) Vibração.

2.1 Estudo dos Parâmetros Estatísticos

Para cada uma das bandas selecionadas para estudo, filtrou-se o sinal referente a três trechos, ao longo da peça usinada, de 400.000 amostras para cada condição (queima, não queima, e alta rugosidade), retirados dos sinais puros de emissão acústica e de vibração, por meio de rotinas desenvolvidas e executadas pelo software *MATLAB*. O filtro utilizado foi do tipo *Butterworth* passa-banda de ordem 6.

Filtrados os vetores dos sinais puros de 400.000 amostras para cada banda selecionada, calculou-se o parâmetro RMS (*root-mean square*) para cada um dos três trechos de cada condição. Obtidos os sinais RMS de EA e de aceleração para cada banda e condição da superfície da peça, calculou-se a média e o desvio padrão. Finalizado esse processo, foi possível obter um gráfico onde cada ponto representa o valor médio em cada uma das faixas de frequências selecionadas para estudo, juntamente com seu respectivo desvio padrão. A figura 3 mostra as etapas desse procedimento.




Figura 3. Processo de geração dos valores médios e desvio padrão para cada banda de frequência.

2.1.1 Arquiteturas e Treinamento das Redes Neurais

Para a determinação do melhor modelo neural, quatro modelos foram utilizados para comparação. No presente estudo, foi avaliado como os resultados dos modelos neurais se comportavam combinando-se 17 entradas (15 entradas referentes aos valores RMS médios dos sinais filtrados para cada banda de frequência e 2 entradas referentes aos valores RMS médios provenientes dos sinais puros não filtrados), e combinando-se apenas as melhores bandas selecionadas nas curvas de amplitude do sinal em função das faixas de frequências.

Para os modelos neurais considerados neste estudo, duas camadas intermediárias foram adotadas com cinco neurônios cada, alterando-se apenas as entradas desses modelos. Essa estrutura neural foi escolhida com base em testes manuais previamente realizados, nos quais foi possível observar que ela apresentava os melhores resultados. Entretanto, para um futuro estudo, serão realizadas combinações de um número bem maior de arquiteturas neurais com o emprego de um algoritmo, a fim de se

determinar a melhor arquitetura neural. O algoritmo de Levenberg-Marquardt foi usado para o treinamento dos modelos neurais.

Para obtenção dos vetores de entradas dos modelos neurais, os vetores RMS foram divididos em 200 partes para cada ensaio, e calculava-se o valor médio de cada parte. O processo ocorreu para os dois sinais (EA e Vibração), gerando-se um conjunto de 2.600 padrões para treinamento dos modelos neurais. A proporção de 60% dos dados foi separada para treinamento, 20% para validação, e 20% para a fase de teste.

O primeiro modelo possuiu 17 entradas (RMS de todas as bandas de EA e VIB juntamente com RMS dos sinais de EA e VIB não filtrados) e 3 saídas, que classificavam os dados em queima, sem queima e rugosidade alta. O segundo e terceiro modelo possuíam apenas duas entradas e as mesmas saídas; o segundo modelo com dois vetores RMS de entrada obtidos a partir dos sinais puros de EA filtrados em duas bandas previamente selecionadas, e o terceiro modelo com dois vetores RMS de entrada obtidos a partir dos sinais puros de vibração filtrados em duas bandas selecionadas. Por fim, a quarta rede neural utilizou quatro entradas e as mesmas saídas mencionadas, sendo as entradas compostas pelos vetores de entradas do modelo 2 e modelo 3.

3 Resultados e Discussão

Com as curvas obtidas a partir dos valores médios dos sinais RMS em função das bandas de frequência, foi possível identificar quais bandas melhor caracterizavam as condições da superfície usinada para cada sinal, como mostra a figura 4. A escolha das melhores bandas se deu, observando-se as amplitudes dos sinais de EA em função da frequência que mais diferenciavam as condições do acabamento superficial dos corpos de prova, conciliando o menor desvio padrão possível. Deste modo, identificou-se que as melhores faixas de frequência foram 51kHz - 62kHz (B2 - EA), 180kHz - 188kHz (B8 - EA), 7kHz - 8kHz (B2 - VIB), e 16kHz e 18kHz (B5 - VIB).

Os resultados dos modelos neurais são apresentados na tabela 2, onde é possível observar que a combinação dos dois sinais (EA e vibração) nas faixas de frequências EA-B2 e VIB-B2, produziu a melhor porcentagem de acertos de classificação dos padrões.

A Figura 5 mostra a matriz de confusão do melhor modelo neural, a qual foi obtida com 20% dos dados não apresentados à RN na fase de treinamento. Observa-se nesta figura que a rede apresentou boa capacidade de classificação dos padrões, especialmente na classe sem

queima com 100% de acertos. Para a classe de queima, a rede produziu 8 falsos negativos, os quais foram classificados como sendo da classe de alta rugosidade. Para a classe de alta rugosidade, 4 falsos negativos são observados, ou seja, a rede classificou como queima da peça.

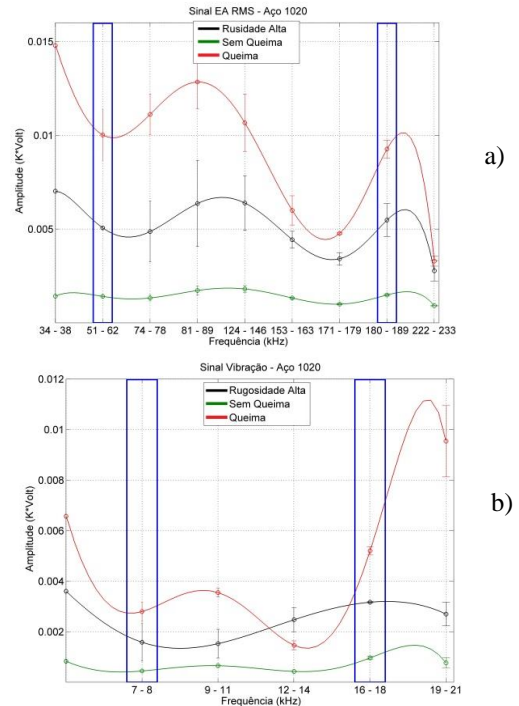


Figura 4. Valores médios do sinal RMS em função das bandas de frequência. a) Emissão Acústica b) Vibração

Tabela 2. Resultados das classificações de cada arquitetura de Rede Neural.

Modelo da Rede	Acerto
17 Entradas – Todas as Bandas + 2 vetores RMS não filtrados de EA e VIB	93,7%
2 Entradas – EA-B8 e VIB-B5	93,3%
2 Entradas – EA-B2 e VIB-B2	96,0%
4 Entradas – EA-B8, VIB-B5; EA-B2, VIB-B2	92,3%

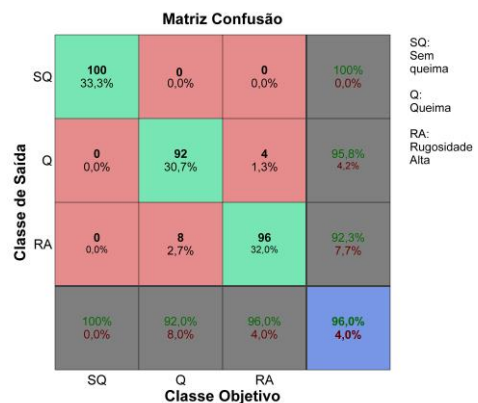


Figura 5. Matriz confusão do modelo de 2 entradas (EA-B2 e VIB-B2).

Observa-se na matriz de confusão, mostrada na Figura 5, que o melhor modelo apresentou 8 falsos negativos para a condição de queima, ou seja, o modelo classificou a peça como possuindo alta rugosidade, sendo que, de fato, houve a queima na superfície da mesma. Além disso, o modelo produziu 4 falsos negativos na condição de alta rugosidade, ou seja, o modelo classificou a condição da peça como queimada quando, na verdade, ocorreu alta rugosidade. Em ambos os casos de falsos negativos, pode-se inferir que os dados de entrada possuem certas semelhanças, uma vez que as peças que sofreram queima também possuem rugosidade alta.

5 Conclusão

O presente trabalho verificou que a combinação dos sinais de emissão acústica e vibração consegue classificar de modo satisfatório uma superfície sem queima, com queima e com alta rugosidade.

A rede neural que melhor classificou os padrões relacionados a condição da superfície da peça foi aquela com 2 camadas ocultas, 5 neurônios cada, e duas entradas: EA na faixa de 51kHz - 62kHz, e VIB na faixa 7kHz - 8kHz. Esta rede apresentou 96% de acerto, sendo que os erros se deram entre a classe de queima e rugosidade alta. Como ambas as condições superficiais da peça são indesejáveis ao processo de retificação, conclui-se que esses erros de classificação não produzirão consequências importantes na fabricação de peças, pois nos dois casos o processo de retificação deverá ser interrompido.

Um estudo futuro será realizado, buscando usar novas estatísticas de modo a se obter resultados ainda melhores na classificação de superfícies retificadas.

Agradecimentos

Os autores agradecem a CAPES e CNPq pelo suporte financeiro concedido.

Referências

- Aguiar, P. R; Bianchi, E. C. and Oliveira, J. F. G (2002). A method for burning detection in grinding process using acoustic emission and effective electrical power signals. *CIRP Journal of Manufacturing Systems*, Paris, Vol. 31, No. 3, pp. 253-257.
- Ahmadzadeh, F. and Lundberg, J (2013). Remaining useful life prediction of grinding mill liners using an artificial neural network. *Minerals Engineering*, Vol. 53, pp. 1-8
- Babel, R; Koshy, P. and Weiss, M (2013). Acoustic emission spikes at workpiece edges in grinding: Origin and applications. *International Journal of Machine Tools and Manufacture*, Vol. 64, pp. 96-101.
- Cruz, C. E. D; Aguiar, P. R; Machado, A. R; Bianchi, E. C; Contrucci, J. G. and Castro N. F (2012). Monitoring in precision metal drilling process using multi-sensors and neural network. *International Journal of Advanced Manufacturing Technology (Internet)*, Vol. 66, pp. 151-158.
- Irani, R.A; Bauer, R.. and Warkentin, A. (2005). A review of cutting fluid application in the grinding process. *International Journal of Machine Tools and Manufacture*, Vol. 45, No. 15, pp. 1696-1705.
- Kim, H. Y., Kim, S. R., Ahn, J. H., Kim, S. H. (2001). Process monitoring of centerless grinding using acoustic emission. *Journal of Materials Processing Technology*, Vol. 111, pp. 273-278.
- Lee, S. E. and Kim, N. H. (2001). A study on the machining characteristics in the external plunge grinding using the current signal of the spindle motor, *International Journal of Machining Tools & Manufacture*, Vol. 41, pp. 937-951.
- Liao, T. W; Tang, F; Qu, Q. and Blau, P.J. (2008). Grinding wheel condition monitoring with boosted minimum distance classifiers. *Mechanical Systems and Signal Processing*, Vol. 22, pp. 217-232.
- Marzi, H. (2008). Modular neural network architecture for precise condition monitoring. *IEEE Transactions on Instrumentation and Measurement*, Vol. 57, No. 4, pp. 805-812.
- Sadeghiamirshahidi, M; Kish, T. E. and Ardejani, F. D. (2013). Application of artificial neural networks to predict pyrite oxidation in a coal washing refuse pile. *Fuel*, Vol. 104, pp. 163 - 169.
- Susic, E. and Grabec, I. (2000). Characterization of the grinding process by acoustic emission. *International Journal of Machine Tools and Manufacture*, Vol. 40, pp. 225-238.
- Teti, R; Jemielniak, K; O'Donnell, G. and Dornfield, R. (2010). Advanced monitoring of machining operations. *CIRP Annals - Manufacturing Technology*, Vol. 59, No. 2, pp. 717-739.
- Wegener, K; Hoffmeister, H. W; Karpuschewski, B; Kuster, F; Hahmann, W.C. and Rabiey, M. (2011). Conditioning and monitoring of grinding wheels. *CIRP Annals - Manufacturing Technology*, Vol. 60, No. 2, pp. 757-777.