

IDENTIFICAÇÃO DO MOMENTO IDEAL DE TROCA DE FERRAMENTAS DE CORTE ATRAVÉS DO MONITORAMENTO DO DESGASTE POR SINAL DE VIBRAÇÃO E INTELIGÊNCIA ARTIFICIAL

Lucas Costa Brito ⁽¹⁾ (brito.lcb@gmail.com), Márcio Bacci da Silva ⁽¹⁾ (mbacci@ufu.br),
Marcus Antonio Viana Duarte ⁽¹⁾ (mvduarte@ufu.br)

⁽¹⁾ Universidade Federal de Uberlândia (UFU); FEMEC - Faculdade de Engenharia Mecânica

RESUMO: *Uma das variáveis mais importantes no processo de usinagem é o desgaste da ferramenta. Assim, o monitoramento do desgaste das ferramentas de corte torna-se essencial para garantir o sucesso do produto, aumentar a produtividade, reduzir o impacto ambiental e evitar danos catastróficos. Para contornar as dificuldades das técnicas tradicionais de monitoramento do desgaste, propõe-se uma nova abordagem na aplicação de técnicas de inteligência artificial não supervisionadas. O objetivo principal do trabalho é identificar o momento ideal de troca da ferramenta com base no sinal de vibração coletado durante o processo de torneamento. A partir de sinais de vibração, utilizou-se redes neurais mapas auto-organizáveis (SOM), para identificar a condição de desgaste da ferramenta. Conjunto de dados desbalanceados para tornar as análises mais próximas da realidade industrial foram utilizados. Realizou-se testes com ferramentas em diferentes condições de desgaste e variando os parâmetros de corte. Os resultados obtidos permitem concluir que é possível avaliar a condição de desgaste da ferramenta de corte com a técnica de inteligência artificial aplicada, utilizando somente o sinal de vibração com taxas de acerto de até 92 %. Além disso, a metodologia permite aplicações industriais por utilizar uma técnica não supervisionada.*

PALAVRAS-CHAVE: *Redes Neurais SOM, Monitoramento, Ferramentas de Corte, Torneamento.*

IDENTIFICATION OF THE TIME TO EXCHANGE CUTTING TOOLS THROUGH WEAR MONITORING USING VIBRATION SIGNALS AND ARTIFICIAL INTELLIGENCE

ABSTRACT: *One of the most important parameters in machining process is tool wear. Thus, monitoring the wear of cutting tools is essential to ensure product quality, increase productivity, reduce environmental impact and avoid catastrophic damages. To overcome the difficulties of traditional wear monitoring techniques, a new approach is proposed in the application of unsupervised artificial intelligence techniques. The main objective of this work is to identify the ideal tool change time based on the vibration signal collected during the turning process. Based on vibration signals, self-organizing maps (SOM) neural networks were used to identify the wear condition of the tool. Imbalanced data sets were used to simulate the industrial reality. Tests were carried out with tools in different wear conditions and varying the cutting parameters. The results showed that it is possible to evaluate the wear condition of the cutting tool with the applied artificial intelligence technique, using only the vibration signal with up to 92% accuracy. In addition, the methodology allows industrial applications as it is an unsupervised technique.*

KEYWORDS: *Self-Organizing Maps (SOM), Monitoring, Cutting Tools, Turning.*

1. INTRODUÇÃO

O desgaste da ferramenta de corte é uma das consequências inerentes do processo de usinagem, o que torna o monitoramento da mesma essencial para garantia da qualidade, confiabilidade e produtividade dos sistemas de fabricação. Visando evitar as consequências dos desgastes trocas desnecessárias de ferramentas são frequentemente realizadas. Estudos mostram que ferramentas de usinagem em máquinas de comando numérico são trocadas com apenas 50 a 80% de sua vida útil, Liu et al. (2018 a,b). Essa prática além de aumentar o custo de produção, tem alto impacto ambiental em função da quantidade de energia e material necessário para produzir uma ferramenta. O monitoramento on-line do desgaste da ferramenta possibilita determinar o momento ideal de troca da ferramenta, resultando no aumento da produtividade, otimização dos custos de processo, e cumprimento das políticas atuais de zero-defeito de produção, Mikołajczyk et al. (2018).

Ao longo do processo de usinagem, devido principalmente ao desgaste, a ferramenta tem sua geometria inicial alterada, influenciando diretamente na qualidade do produto e nas tolerâncias dimensionais alcançadas. O aumento do raio de ponta da ferramenta por exemplo, pode influenciar significativamente as tensões residuais numa peça, Liu et al. (2004). Além disso, desgastes severos podem resultar na quebra inesperada da ferramenta, que por sua vez, pode ocasionar quebras ainda maiores, como o de componentes da máquina ferramenta, Rizal et al. (2017).

Monitorar o desgaste não é uma tarefa simples, principalmente devido a natureza do desgaste, Kannatey-Asibu et al. (2017). Normalmente, mais de um mecanismo de desgaste pode estar envolvido no processo. Trent e Wright (2000) por exemplo, identifica 6 mecanismos distintos de desgaste numa ferramenta de usinagem: abrasão, adesão, difusão, cisalhamento superficial a altas temperaturas, deformação plástica e entalhe. A presença de diversos mecanismos de desgaste dificulta ainda mais a determinação dos corretos parâmetros para criação um sistema que seja capaz de identificá-lo, Nouri et al. (2015). No monitoramento direto, outros fatores dificultam ainda mais a determinação da condição de vida da ferramenta, tais como: a presença do fluido de corte, impossibilitando as medições do desgaste com microscópio ou a necessidade de parar a máquina para uma medição mais precisa. No caso de medição através da rugosidade da peça, a complexidade das peças torna a medida de rugosidade ainda mais complicada.

Uma forma alternativa para monitorar o desgaste é utilizar métodos indiretos. Ou seja, monitorar e analisar parâmetros obtidos através de sinais de vibração, emissão acústica, força de corte, temperatura de corte, torque e corrente do motor principal, por exemplo.

Dentre as várias possibilidades de monitoramento indireto, pesquisas mostram o sucesso da utilização do sinal de vibração para classificação da condição de desgaste da ferramenta, Siddhpura

e Paurobally (2013). Rizal et al. (2017) durante o estudo em fresamento utilizando multi-sensores e *Mahalanobis-Taguchi system* (MTS) mostrou ser o sinal de vibração um dos parâmetros de maior relevância para o método de classificação, com acurácia média de 88.89%. Sevilla et al. (2015 a,b) mostraram que devido a seu baixo custo e fácil instalação, sensores de vibração são amplamente utilizados em monitoramento da condição da ferramenta (*Tool Condition Monitoring* - TCM). Prasad e Babu (2017) provaram que no processo de torneamento existe grande correlação entre o sinal de vibração e o desgaste da ferramenta, através da análise numérica e experimental, avaliando a amplitude do sinal e o desgaste. Rmili et al. (2016) propuseram um método de identificação da condição da ferramenta baseado na análise de vibração alinhado a um sistema automático de detecção em processo de torneamento.

Alinhado a utilização de sinais de vibração, e outros métodos de medição indireto, diversos estudos, como mostrado em Zhou e Xue (2018), vêm sendo realizados com objetivo de desenvolver modelos de inteligência artificial confiáveis para a identificação da condição de desgaste da ferramenta de corte. Yen et al. (2013) utilizaram a técnica *self-organization feature map* (SOM) juntamente com o sinal de emissão acústica (AE) para monitoramento do desgaste da ferramenta na microusinagem, obtendo uma taxa de classificação média de 98% para a condição da ferramenta. Da Silva et al. (2016) aplicaram uma rede neural probabilística para classificação da condição de desgaste em operação de fresamento, obtendo até 91% de acerto. Hassana et al. (2018) compararam seis *benchmarks* para classificar desgaste da ferramenta, dentre elas, redes neurais, *support vector machine* (SVM) e *k-nearest neighbor* (kNN), obtendo até 90% de acerto com SVM.

A maioria dos estudos de TCM trabalha com modelos em que os dados são balanceados (o que, em geral, facilita a aprendizagem do modelo), ou seja, mesma quantidade de sinais para classes (no caso do trabalho, normal e desgastada). Além disso, os classificadores são supervisionados, o que não representa a realidade industrial, limitando sua aplicação. Além disso, muitos trabalhos incluem mais de um sensor, o que pode contribuir para aumentar o custo de implementação em larga escala.

Portanto, o objetivo desse trabalho é desenvolver um método utilizando técnica de inteligência artificial não supervisionada para identificar o momento ideal de troca da ferramenta de corte. Para isso, propôs a utilização de uma rede neural SOM. Em função da ampla gama de aplicações e baixo custo de implementação optou-se por utilizar o monitoramento através do sinal de vibração.

O trabalho encontra-se organizado da seguinte forma. Seção 2 tem-se uma breve explicação sobre o método utilizado. Na seção 3 a metodologia é apresentada. A montagem dos testes e aquisição dos sinais são discutidos na seção 4. Na seção 5 tem-se as análises dos resultados obtidos. E por fim, a seção 6 conclui o trabalho.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Rede Neural SOM (Self-Organizing Map)

A rede SOM foi implementada com sucesso em inúmeras aplicações, em áreas como identificação de falhas, classificação, reconhecimento de voz e análise de *cluster* (Lia et al. 2018; Mikaeil et al. 2018; Lokesh et al. 2019; Mutheneni et al. 2018; Jain et al. 2018; Burnap et al. 2018).

O procedimento basicamente se resume em uma transformação não linear de um espaço de alta dimensão para um espaço com baixa dimensão Cai et al. (2014). Automaticamente, as amostras do conjunto de dados são agrupadas de acordo com suas similaridades, separando aquelas com características diferentes em outros grupos.

A arquitetura da SOM corresponde a uma rede neural com uma camada competitiva bidimensional ou unidimensional, onde existe interação lateral entre os neurônios dentro de uma vizinhança. A rede combina competição como uma forma de aprendizagem objetivando o melhor ajuste dos pesos. Primeiramente, inicia-se os pesos com valores aleatórios pequenos. Em seguida, o conjunto de entrada é apresentado. Através da técnica de quantização vetorial, calcula-se a similaridade, definindo a unidade de melhor correspondência (*best matching unit* - BMU), minimizando o erro de quantização Cai et al. (2014) e o neurônio vencedor é tido como vizinhança topológica.

Baseados nas respostas anteriores, o modelo é atualizado ajustando os pesos até a convergência final determinada, como apresentado na Equação 1, Kohonen (1995), onde m_i é o vetor de referência mais próximo de x , t é o índice dos passos de regressão, x é a amostra, $h_{c(x),i}$ é a função da vizinhança e α a taxa de aprendizado.

$$m_i(t+1) = m_i(t) + \alpha(t)h_{c(x),i}(x(t) - m_i(t)) \quad (1)$$

Em resumo, primeiro realiza-se o treinamento não supervisionado com base nos dados apresentados e no processo competitivo supracitado. Posteriormente, realiza-se a classificação dos novos dados em relação aos mapas definidos no treinamento Kohonen (1995).

3. METODOLOGIA

Os testes experimentais foram realizados no torno CNC e os sinais de vibração das ferramentas coletados em diferentes condições de desgastes. Foram utilizadas duas condições de usinagem, para teste e validação do método. Os sinais adquiridos foram processados e parâmetros vibratórios extraídos para serem utilizados como entradas no sistema de classificação.

Para seleção dos parâmetros vibratórios que melhor representam a condição de desgaste da ferramenta, realizou-se a normalização dos dados e o Teste de Grubbs a fim de eliminar valores extremos (*outliers*) do grupo considerado em condições de desgaste normal. O teste t de comparação da população foi aplicado para selecionar os parâmetros vibratórios. Os parâmetros selecionados através do teste t , foram utilizados como entrada para treinamento dos classificadores, possibilitando a classificação de novas ferramentas.

3.1. Extração dos parâmetros

Os parâmetros de entrada dos modelos de inteligência artificial devem ser escolhidos cuidadosamente a fim de contribuir na criação de modelos com boa generalização e alta assertividade. Além de evitar problemas como *overfitting* e *underfitting* e reduzir custo computacional dos mesmos. Selecionar os parâmetros que apresentam correlação com o desgaste da ferramenta é a chave para o sucesso do modelo, Xie et al. (2019). Para o estudo, 71 parâmetros relacionados a análise estatística, domínio do tempo, e frequência foram extraídos dos sinais brutos de vibração, Tabela 1.

TABELA 1. Parâmetros estatístico, domínio do tempo e frequência. Fonte: Autor (2020).

Número do Parâmetro	Descrição
1	Média
2	Assimetria (<i>Skewness</i>)
3	Curtose (<i>Kurtosis</i>)
4	Valor Pico
5	Valor Pico-a-Pico
6	Nível RMS em função da amplitude do sinal
7	Fator de Crista
8	K4 [$10\log_{10}(\text{RMS} \cdot \text{Curtose})$]
9-29	Energia em bandas de frequências
30-71	Energia em envelope em bandas de frequências

3.2. Pré-processamento dos dados

Os dados foram pré-processados para garantir a eficiência do método. A normalização foi realizada de acordo com Equação 2, Lu e Wan (2013), onde (x_{max}^j) é o valor máximo e (x_{min}^j) o valor mínimo das amostras para cada parâmetro (j), sendo (X_i^j) o valor para o j parâmetro da amostra i .

$$(X_i^j) = \frac{x_i^j - x_{min}^j}{x_{max}^j - x_{min}^j} \quad (2)$$

Teste de Grubbs foi utilizado para identificação dos valores extremos (*outliers*) no grupo de treinamento, Wang et al. (2018), Grubbs (1969). O teste t foi utilizado para definir os parâmetros que apresentam maior correlação com o desgaste da ferramenta. Os parâmetros que resultaram em maiores valores da razão $T = t/t_{crítico}$ foram selecionados. O cálculo da razão t é realizado com duas hipóteses básicas acerca da média, sendo $H_0: \mu_1 = \mu_2$ e $H_1: \mu_1 \neq \mu_2$, onde μ_1 e μ_2 são as médias populacionais dos parâmetros das ferramentas com desgaste normal e crítico, respectivamente.

Utilizando uma alternativa bilateral, tem-se que a hipótese nula (H_0) será rejeitada com nível de significância (α) de 5%, se $t > t_{críticosuperior}$ ou $t < t_{críticoinferior}$.

3.3. Treinamento, teste e modelo

O método não supervisionado SOM foi utilizado. A rede SOM foi formada por duas dimensões, taxa de aprendizado 0.01, valor mínimo de performance do gradiente de $1e-5$, valor máximo de épocas de treinamento de 1000 e tamanho inicial da vizinhança 10.

Para avaliar os métodos de classificação realizou-se testes em duas condições de corte, determinadas conjuntos a e b .

Ressalta-se que os dados de treinamento e validação são diferentes, sendo 70% dos sinais para treinamento e 30% para validação. A mesma quantidade de dados foi mantida nas duas análises. Além disso, o treinamento e validação foram realizados 200 vezes para diferentes conjuntos de dados que foram criados aleatoriamente para cada teste a fim de confirmar a robustez do classificador. O resultado final foi a média das análises.

4. PROCEDIMENTO EXPERIMENTAL

4.1. Processo de torneamento

Os testes foram realizados em um torno CNC, ROMI Multiplic-35D, com 11 kW de potência no motor principal e 20 kVA de potência instalada, com velocidade máxima no rotor de 3000 rpm. O material da peça utilizada no trabalho foi o aço AISI D6 com composição química: 2,10% C, 11,50% Cr, 0,70% W e 0,15% V.

As ferramentas utilizadas foram de PCBN, do fabricante Sandvik Coromant, classe CB7015, com 50% CBN e ligante cerâmico, com geometria SNGA120412 S01030A CB7015. A faixa de trabalho

indicada pelo fabricante para a utilização da ferramenta na usinagem de aços endurecidos é velocidade de corte (V_c) de 150-250 m/min, avanço (f) 0,05 - 0,30 mm/rev. e profundidade de corte (a_p) de 0,07 - 1,20 mm. As condições utilizadas são apresentadas na Tabela 2.

TABELA 2. Condições de corte. Fonte: Autor (2020).

Conjunto	V_c	a_p	f
Conjunto (a)	200 m / min	0,2 mm	0,1 mm / rev
Conjunto (b)	150 m / min	0,1 mm	0,05 mm / rev

Situações típicas de desgaste envolvem mais de um tipo de desgaste, entretanto do ponto de vista de processo, o desgaste de flanco, V_b , é o mais importante, sendo a variável mais comum a ser utilizada para avaliação da condição da ferramenta, Liu et al. (2018a).

Seguindo as recomendações padrões de desgaste, definiu-se como critério de fim de vida útil quando V_b atingisse 0,30 mm. Para o conjunto (a), foram utilizadas 12 ferramentas, sendo 5 ferramentas em condição normal de desgaste, definida por V_b menor que 0,30 mm e 7 ferramentas com desgaste crítico, nas quais V_b era maior que 0,30 mm. Para o conjunto (b), utilizou-se 5 ferramentas, inicialmente novas, que foram utilizadas até a condição de desgaste crítico. Os ensaios foram realizados de maneira aleatória e as ferramentas utilizadas pertenciam a lotes distintos para evitar erros sistemáticos.

O desgaste de flanco medido após cada passe através da análise da superfície de folga em um estéreo microscópio, SZ61 - Olympus, com câmara digital integrada, com ampliação de 40 X. Antes de cada medição realizou-se a calibração do estéreo microscópio por meio de uma escala graduada. Para cada ferramenta inspecionada, foram realizadas três medições, obtendo a média dos valores, o que assegura a confiabilidade estatísticas das mesmas.

Em resumo, utilizou-se um total de 17 ferramentas no teste, considerando os conjuntos a e b, com os intervalos de desgaste de flanco sendo: desgaste normal [$V_b = 0 - 0,30$ mm] e desgaste crítico [$V_b > 0,30$ mm].

4.2. Aquisição dos sinais

Os acelerômetros foram fixados nas posições vertical (direção de corte) e horizontal (direção de avanço). Utilizou-se dois acelerômetros *Brüel & Kjær* com sensibilidades 2,06 pC/m/s² e

1,00 pC/m/s² conectados a dois amplificadores de carga *Brüel & Kjær* modelo 2635, e posteriormente a uma placa de aquisição de sinais da National Instruments, de 32 bits, 4 canais.

O sistema de monitoramento foi acoplado ao microcomputador, os dados foram coletados e salvos para posterior análise. O aparato experimental é apresentado na Figura 1.

Com base nas análises previamente desenvolvidas sobre o sistema, onde-se coletou sinais com frequências de amostragem maiores que a utilizada, verificou-se que com frequência de aquisição de 25 kHz e tempo de coleta de 11 segundos, o sinal de vibração abrangeria todas as excitações que poderiam influenciar no desgaste da ferramenta. Foram coletados 132 sinais de vibração, para o conjunto *a* e 115 sinais par o conjunto *b*.




FIGURA 1. Montagem do aparato experimental. Fonte: Autor (2020).

5. RESULTADOS E DISCUSSÕES

Os sinais de vibração brutos no domínio do tempo e da frequência para a ferramenta aleatoriamente selecionada, podem ser observados na Figura 2, com um tempo total de coleta de 11 s, janela *hanning*, *overlap* de 50 % e *df* 6.10 Hz. Nessa etapa, tendo como objetivo apresentar somente o comportamento geral do sinal, não foram realizadas tratamento dos dados para plotagem das figuras. Posteriormente, esses processos foram realizados para extração dos parâmetros vibratórios.




FIGURA 2. Sinal de vibração para ferramenta em estado normal $V_B = 0,119$ e desgastada $V_B = 0,353$, no domínio do tempo (a) e frequência (b). Fonte: Autor (2020).

Nota-se pela análise da Figura 2 (a) que existe um aumento da amplitude de vibração com o aumento do desgaste, ou seja, existe uma correlação entre as grandezas, assim como mostrado por Prasad e Babu (2017). Além disso, quando comparado duas ferramentas com grande diferença na condição de desgaste, esse aumento é visualmente perceptível. Nota-se também pela na Figura 2 (b) que algumas bandas de frequência apresentam maior correlação com o desgaste do que outras.

Os sinais de vibração brutos no domínio do tempo e da frequência para ferramentas com valores próximos de desgaste são mostrados na Figura 3.




FIGURA 3. Sinal de vibração para ferramenta em estado normal $V_B = 0,267$ e desgastada $V_B = 0,321$, no domínio do tempo (a) e frequência (b). Fonte: Autor (2020).

Como pode ser visto, quando o desgaste das ferramentas se encontra muito próximo, é muito difícil classificar a condição da ferramenta apenas observando o sinal. Portanto, para definir o momento ideal da troca de forma automatizada, justifica-se a aplicação de uma técnica de inteligência artificial.

Primeiramente a fim de verificar, e evitar, a presença de valores extremos na amostra (*outliers*), utilizou-se o Teste de Grubbs. Dos testes realizados eliminou-se 5 sinais do conjunto *a*, resultando em um total de 127 sinais de vibração para o conjunto *a*, e 115 sinais de vibração para o conjunto *b*, já que nenhum sinal foi considerado *outlier* nesse conjunto.

Os parâmetros de vibração que melhor caracterizaram o problema em análise foram verificados através do Teste *t*. Após análises dos parâmetros mais relevantes, realizou-se uma varredura, para determinar quantos parâmetros seriam utilizados como dados de entrada nos classificadores. A varredura foi realizada testando combinações entre os 71 parâmetros definidos, e utilizando aquela que obteve maior taxa de acerto na classificação da ferramenta quanto ao desgaste.

Os parâmetros utilizados, por sua vez, foram os que obtiveram maior *t-ratio*. Para o conjunto *a* utilizou-se três parâmetros, sendo: energia do sinal filtrado na banda de frequência de 500 a 3000 Hz, energia do envelope do sinal filtrado na banda de frequência de 6000 a 8000 Hz e energia do envelope do sinal com filtro passa baixo em 7000 Hz. Para o conjunto *b*, dois parâmetros: nível de energia do sinal filtrado na banda de frequência de 500 a 3000 Hz e energia do envelope do sinal filtrado na banda de frequência de 500 a 3000 Hz.

Analisando a classificação da condição das ferramentas obteve-se taxa de acerto (acurácia) de 92% para o conjunto *a* e 87% para o conjunto *b*. Além do valor de acurácia, a matriz de confusão para ambos os testes é apresentada na Tabela 3 e 4, respectivamente.

TABELA 3. Matriz de Confusão - Conjunto *a*. Fonte: Autor (2020).

Valores Reais	Normal	88,2 %	11,8 %
	Desgastada	0,0 %	100 %
		Normal	Desgastada
Valor Predito			

TABELA 4. Matriz de Confusão - Conjunto *b*. Fonte: Autor (2020).

Valores Reais	Normal	100 %	0,0 %
	Desgastada	17,6 %	82,4 %
		Normal	Desgastada
Valor Predito			

. Por se tratar de um classificador não supervisionado, trabalhando com dados desbalanceados, as taxas obtidas pela rede SOM, foram consideradas satisfatórias, principalmente para o Conjunto **a**. A menor taxa de acerto obtida para o Conjunto **b**, pode ser justificado pelas condições de testes adotadas ao conjunto **b** que resultaram na maior quantidade de dados próximos a zona de transição entre desgaste normal e crítico, dificultando a análise pelo classificador.

Analisando a Tabela 3, pode-se verificar que no Conjunto **a** todas as ferramentas consideradas em condição de desgaste foram classificadas corretamente. Por outro lado, algumas ferramentas consideradas normais foram classificadas como desgastadas, implicando em um erro de classificação. Analisando os sinais correspondente aos 11,8% de erro, notou-se que 10,2% são relacionados a ferramentas com valor de desgaste medido entre 0,27 mm e 0,32 mm, os quais estão muito próximo da zona de transição, e que pode até mesmo, estarem associados a desvio de medição do desgaste no microscópio e não a um erro do classificador. Portanto, avalia-se que a precisão do método se encontra satisfatória. Os demais sinais (1,6 % do erro) foram considerados realmente erro de classificação por não apresentarem justificativa plausível. O fato de o classificador acertar todas as amostras em condição de desgaste permite uma segurança na operação, evitando que ferramentas fora das condições ideais operem, e consequentemente identificando o momento ideal de troca. Evitando também maiores danos que podem ser causados pela quebra da ferramenta durante a operação.

Avaliando o Conjunto **b**, Tabela 4, nota-se que todas as ferramentas em condição normal foram classificadas corretamente, implicando erros apenas na classificação das ferramentas com desgaste crítico. Novamente, analisando os sinais correspondente aos 17,6% de erro, notou-se que 15,1% são ferramentas com valor de desgaste medido entre 0,28 mm e 0,31 mm, os quais estão muito próximo da zona de transição e também podem estarem associados a desvio de medição do desgaste no microscópio e não a um erro do classificador. Concluindo também, que a precisão do método se encontra satisfatória. Em relação aos demais sinais (2,5 % do erro) não foram encontrados justificativas plausíveis.

Ressalta-se que caso as condições de operação, material e/ou máquina sejam diferentes das condições em que o classificador foi treinado é necessário treiná-lo novamente para as condições atuais. Afirma-se também, que apesar da necessidade de treinar novamente o sistema, isso não implica em uma limitação do método e sim em uma condição inicial de funcionamento.

6. CONCLUSÕES

Este trabalho apresenta uma metodologia não supervisionada utilizando dados desbalanceados para classificar o desgaste da ferramenta. Tendo como objetivo principal determinar se a ferramenta apresenta condição normal ou desgastada, e consequentemente o momento ideal de troca.

Duas diferentes condições de usinagem foram utilizadas a fim de validar o método, e diversos sinais de vibração coletados para monitorar o processo. Os parâmetros que melhor identificam as diferenças para a condição normal e desgastada foram extraídos com base nos testes estatísticos. Na metodologia proposta, utilizou-se uma rede neural SOM para identificação da condição de desgaste da ferramenta.

Nota-se que o sinal de vibração é capaz de caracterizar o desgaste da ferramenta, sendo uma boa técnica de monitoramento, confirmando os estudos apresentados na literatura. Além disso, através dos resultados obtidos, pode-se concluir que é possível utilizar somente o sensor de vibração, ao invés da combinação de vários outros sensores, o que implicaria em um aumento de custo para implementações industriais em grande escala.

Para este estudo, as faixas de frequência entre 500 a 3000 Hz e 6000 a 8000 Hz estão intimamente relacionadas a mudanças na condição da ferramenta. O nível de energia do envelope e o nível de energia do sinal filtrado são parâmetros que também se correlacionam bem com o desgaste da ferramenta.

Por fim, com uma taxa de acerto de até 92 %, mostra-se que a metodologia proposta pode ser utilizada para identificar o momento ideal de troca da ferramenta. A metodologia opera como um sistema de classificação do desgaste da ferramenta durante o processo de torneamento sem ser necessário parar o mesmo. Além disso, por se tratar de um sistema não supervisionado, trabalhando com dados desbalanceados e apenas sensor de vibração, possibilita sua implementação no âmbito industrial. Ressalta-se a importância de realizar o treinamento do sistema para as condições de operação atual do equipamento.

REFERÊNCIAS

Burnap, P., French, R., Turner, F., & Jones, K. (2018). Malware classification using self organising feature maps and machine activity data. *Computers & Security*, 73, 399–410.

Cai, Q., He, H., & Man, H. (2014). Imbalanced evolving self-organizing learning. *Neurocomputing*, 133, 258–270.

- Grubbs, F. E. (1969). Procedures for detecting outlying observations in samples. *Technometrics*, 11(1), 1–21.
- Hassana, M., Damirb, A., Attiaa, H., & Thomsona, V. (2018). Bench- marking of pattern recognition techniques for online tool wear detection. *Procedia CIRP*, 72, 1451–1456.
- Kannatey-Asibu, E., Yum, J., & Kim, T. H. (2017). Monitoring tool wear using classifier fusion. *Mechanical Systems and Signal Pro- cessing*, 85, 651–661.
- Kohonen, T. (1995). *Self-organizing maps* (2nd ed.). Berlin: Springer
- Jain, D. K., Dubey, S. B., Choubey, R. K., Sinhal, A., Arjaria, S. K., Jain, A., et al. (2018). An approach for hyperspectral image classification by optimizing SVM using self organizing map. *Journal of Computational Science*, 25, 252–259
- Lia, Z., Fang, H., Huang, M., Wei, Y., & Zhang, L. (2018). Data-driven bearing fault identification using improved hidden Markov model and self-organizing map. *Computers and Industrial Engineering*, 116, 37–46.
- Liu, C., Li, Y., Hua, J., Lu, N., & Mou, W. (2018a). Real-time cutting tool state recognition approach based on machining features in NC machining process of complex structural parts. *The International Journal of Advanced Manufacturing Technology*, 97, 229–241.
- Liu, M., Takagi, J., & Tsukuda, A. (2004). Effect of tool nose radius and tool wear on residual stress distribution in hard turning of bear- ing steel. *Journal of Materials Processing Technology*, 150(3), 234–241.
- Liu, Y., Wang, X., & Yan, K. (2018b). Hand gesture recognition based on concentric circular scan lines and weighted K-nearest neighbor algorithm. *Multimedia Tools and Applications*, 77, 209–223.
- Lokesh, S., Kumar, P. M., Devi, M. R., Parthasarathy, P., & Gokulnath, C. (2019). An automatic tamil speech recognition system by using bidirectional recurrent neural network with self-organizing map. *Neural Computing and Applications*, 31, 1521–1531.
- Lu, M., & Wan, B. (2013). Study of high-frequency sound signals for tool wear monitoring in micromilling. *International Journal of Advanced Manufacturing Technology*, 66, 1785–1792.
- Mikaeil, R., Haghshenas, S. S., & Hoseinie, S. H. (2018). Rock pene- trability classification using artificial bee colony (ABC) algorithm and self-organizing map. *Geotechnical and Geological Engineer- ing*, 36, 1309–1318.
- Mikołajczyk, T., Nowicki, K., Bustillo, A., & Yu Pimenov, D. (2018). Predicting tool life in turning operations using neural networks and image processing. *Mechanical Systems and Signal Processing*, 104, 503–513.
- Mutheneni, S. R., Mopuri, R., Naish, S., Gunti, D., & Upadhyayula, S. M. (2018). Spatial distribution and cluster analysis of dengue using self organizing maps in Andhra Pradesh, India, 2011–2013. *Parasite Epidemiology and Control*, 3, 52–61.

Nouri, M., Fussell, B. K., Ziniti, B. L., & Linder, E. (2015). Real- time tool wear monitoring in milling using a cutting condition independent method. *International Journal of Machine Tools and Manufacture*, 89, 1–13.

Prasad, B. S., & Babu, M. P. (2017). Correlation between vibration amplitude and tool wear in turning: Numerical and experimental analysis. *Engineering Science and Technology, an International Journal*, 20, 197–211.

Rmili, W., Ouahabi, A., Serra, R., & Leroy, R. (2016). An automatic system based on vibratory analysis for cutting tool wear monitor- ing. *Measurement*, 77, 117–123.

Rizal, M., Ghani, J. A., Nuawi, M. Z., & Haron, C. H. C. (2017). Cutting tool wear classification and detection using multi-sensor signals and Mahalanobis-Taguchi system. *Wear*, 376–377, 1759–1765.

Sevilla, P., Robles, J., Jauregui, J., & Jimenez, D. (2015a). FPGA-based reconfigurable system for tool condition monitoring in high-speed machining process. *Measurement*, 64, 81–88.

Sevilla, P., Robles, J., Muñiz, J., & Lee, F. (2015b). Tool failure detec- tion method for high-speed milling using vibration signal and reconfigurable bandpass digital filtering. *International Journal of Advanced Manufacturing Technology*, 81, 1187–1194.

Siddhpura, A., & Paurobally, R. (2013). A review of flank wear predic- tion methods for tool condition monitoring in a turning process. *International Journal of Advanced Manufacturing Technology*, 65, 371–393.

Silva, R. H. L., Silva, M. B., & Hassui, A. (2016). A probabilistic neural network applied in monitoring tool wear in the end milling oper- ation via acoustic emission and cutting power signals. *Machining Science and Technology*, 20(3), 386–405.

Trent, E. M., & Wright, P. K. (2000). *Metal cutting* (4th ed.). Oxford: Butterworth-Heinemann.

Xie, Z., Li, J., & Lu, Y. (2019). Feature selection and a method to improve the performance of tool condition monitoring. *The Inter- national Journal of Advanced Manufacturing Technology*, 100, 3197–3206.

Wang, C., Caja, J., & Gómez, E. (2018). Comparison of methods for outlier identification in surface characterization. *Measurement*, 117, 312–325.

Yen, C. L., Lu, M. C., & Chen, J. L. (2013). Applying the self- organization feature map (SOM) algorithm to AE-based tool wear monitoring in micro-cutting. *Mechanical Systems and Signal Pro- cessing*, 34, 353–366.

Zhou, Y., & Xue, W. (2018). Review of tool condition monitoring methods in milling processes. *International Journal of Advanced Manufacturing Technology*, 96, 2509–2523.