

Análise de Relevância de Atributos para Classificação de Falhas de Ferramentas de Corte Utilizando TSFRESH

Matheus A. M. Ferreira, Thiago E. Fernandes, Guilherme P. C. de Miranda,
Marcos V. G. da Silva e Eduardo P. de Aguiar

Resumo—Uma grande parcela de componentes industriais são submetidos a um processo de usinagem durante sua fabricação. Portanto, o monitoramento do desgaste de ferramentas de corte pode resultar em uma redução de custos, aumento de produtividade e segurança. Este trabalho aplica técnicas de processamento de sinais e aprendizado de máquina para resolver esse problema. Considerando uma aplicação do modelo em um sistema embarcado, a análise da relevância e seleção dos atributos se torna imprescindível pela capacidade de reduzir a dimensionalidade do fluxo de dados. O modelo proposto pode identificar padrões que distingam a ferramenta de corte como inadequada ou adequada.

Palavras-Chave—Processamento de Sinais, Análise de Dados, Aprendizagem Computacional

Abstract—The majority of mechanical components went through a machining process during their manufacturing. Therefore, manufacturing processes with inadequate condition tools are likely to induce unexpected operational interruptions, accidents, product quality, and economic losses. This work applies signal processing and machine learning techniques to solve this problem. Considering an application of the model in an embedded system, the analysis of relevance and feature selection becomes essential due to the ability to reduce the data dimensionality. The proposed model can identify patterns that distinguish the cutting tool as inadequate or adequate.

Keywords—Signal Processing, Data Handling, Machine Learning

I. INTRODUÇÃO

Uma pesquisa sobre o mercado mundial ferramentas de corte de 2020 publicada pela Gardner Business Media [1] mostra uma queda no consumo e produção de ferramentas de corte comparado com anos anteriores. A pandemia do coronavírus e o lockdown em diversos países causaram um impacto significativo no mercado de ferramentas de corte.

O consumo global de ferramentas de corte em 2020 foi de US\$66.8 bilhões, uma queda de 20.1% comparando 2019. Entretanto, se levarmos em consideração a queda no consumo de ferramentas de corte durante a crise econômica de 2008/09, os efeitos da pandemia no mercado de ferramentas de corte não foram tão severos como seria esperado [2].

Com a reabertura da economia, a indústria tende a se recuperar e um crescimento semelhante no consumo de ferramentas de corte é esperado. Nesse cenário, a crescente compe-

titividade leva as empresas a exigirem redução no consumo de ferramentas, tempo de manutenção e melhorias na qualidade, disponibilidade e confiabilidade dos processos de fabricação. Consequentemente, a manutenção baseada em condição [3], [4], tem sido amplamente aplicada e é uma das soluções mais efetivas de manutenção preditiva, devido ao seu sucesso em reduzir incertezas envolvendo as atividades de manutenção [5].

Levando em consideração a substituição de ferramentas de corte, as mudanças começaram quando a implementação de mecanismos de inspeção adaptativa permitiu que o procedimento de substituição baseado no monitoramento do desgaste de flanco crescesse [6]. Contudo, esse tipo de procedimento não é aplicável devido ao grande número de variáveis envolvidas (material da peça, material da ferramenta, processo de usinagem, condições de corte, ambiente de fabricação, forças, temperatura, fluido de corte, etc.) o que torna esse tipo de tecnologia cara e subjetiva.

O desenvolvimento de sistemas capazes de supervisionar os processos de usinagem com monitoramento em tempo real ganharam força, assim como as abordagens que diminuem a interferência humana no processo. Além disso, a manutenção preditiva permite evitar falhas, prevenir acidentes e reduzir perdas econômicas. Portanto, a análises de séries temporais por meio de extração e seleção de atributos pode ser útil para melhorar a confiabilidade do processo de usinagem, assim como reduzir o tempo de manutenção, o que leva a uma diminuição de custos.

Em relação às séries temporais, uma importante característica a ser levada em consideração é a alta dimensionalidade dos dados. Logo, essa análise se torna bem difícil para diversos algoritmos, especialmente quando o tempo é levado em consideração. Além disso, mineração de dados geralmente requer alto custo computacional quando aplicado a um grande volume de dados. Assim a redução da dimensionalidade dos dados através da extração de atributos se torna necessária. Um dos maiores desafios quando é adotada uma análise de séries temporais é selecionar atributos pertinentes para representar os dados. Considerando essa dificuldade, uma metodologia chamada Extração de Atributos de Séries Temporais baseado em testes de Hipóteses Escalonáveis (TSFRESH - *Time Séries Feature Extraction based on Scalable Hypothesis tests* [7]) foi adotada como solução nesse trabalho.

Em conjunto com o TSFRESH, a fim de reduzir a dimensionalidade dos dados, o método Análise de Componentes Principais (PCA - *Principal Component Analysis* [8]) foi

aplicado. O PCA é um método utilizado para reduzir a dimensionalidade do problema em componentes não correlacionadas que são combinações lineares das variáveis originais. Por meio do cálculo de componentes principais, o PCA proporciona a capacidade de manter a informação dos atributos provenientes da seleção de atributos do TSFRESH em um número reduzido de componentes mantendo uma parcela da variância dos dados.

Nesse contexto a principal contribuição deste trabalho pode ser listada como:

- A análise de relevância dos componentes de frequência da FFT (*Fast Fourier Transform*), através da aplicação do TSFRESH em uma base de dados adquirida em um sistema real de usinagem.
- O uso de técnicas de processamento de sinais em conjunto com aprendizado de máquina através de classificadores implementados utilizando a biblioteca *Scikit-Learn* [9], na classificação de ferramentas de corte de torno.

E as principais conclusões são:

- A abordagem proposta pode identificar os padrões que distinguem a condição de uma ferramenta de corte entre adequada e inadequada, alcançando performances satisfatórias em todos os casos e prevenindo falhas na fabricação de peças por usinagem.
- O uso de um filtro digital, a extração de atributos da FFT, seleção de atributos baseada em testes de hipóteses escalonáveis (TSFRESH) e redução de dimensionalidade utilizando PCA se mostraram eficiente para solucionar o problema causado pelas componentes de alta frequência dos sinais originadas pelo acionamento do inversor de frequências WEG CFW500 no motor trifásico do torno.

II. FORMULAÇÃO DO PROBLEMA

As variáveis que compõem as séries temporais utilizadas nesse trabalho foram definidas com o objetivo de monitorar e diagnosticar o desgaste das ferramentas de corte. Logo, tensão e corrente elétrica de cada uma das três fases do motor do torno foram definidas como as variáveis adquiridas, já que a potência de corte tem recebido grande atenção na literatura. A análise dessas grandezas são justificadas pelo fato de que o torno necessita de mais potência para operar com uma ferramenta inadequada do que estaria consumindo caso estivesse funcionando com uma ferramenta adequada [10].

O desgaste de flanco ocorre quando uma parte da ferramenta sofre erosão devido ao atrito com o material que está sendo usinado. A evolução do desgaste de flanco em uma ferramenta de corte utilizada nos experimentos pode ser observado nas Figuras 1 e 2.

O crescimento da potência consumida pelo torno pode ser explicado pelo fato da evolução do desgaste de flanco causar um aumento na área de contato entre a ferramenta e a peça. Consequentemente, existe um aumento no atrito e nas forças de usinagem, o que resulta no aumento do consumo de potência.

A base de dados utilizada nesse trabalho foi adquirida por experimentos em um sistema real de usinagem no Laboratório de Processos de Fabricação, no departamento de Engenharia Mecânica, da Universidade Federal de Juiz de Fora. Este




Fig. 1. Condições iniciais da ferramenta de corte.




Fig. 2. Ferramenta de corte manifestando desgaste de flanco.

processo é regulamentado pela ISO 3685/1993, consistindo na execução de operações sucessivas e examinando a condição da ferramenta em intervalos regulares. O processo de torneamento foi feito em um torno universal Timemaster Tb 350.

Este equipamento usa um inversor de frequências WEG CFW500. A base de dados foi adquirida utilizando o módulo de aquisição de dados da National Instruments USB-6210 conectado as três fases do motor do torno.

O inversor de frequência WEG CFW500, está configurado para operar com um sistema de controle Vetorial de Tensão (VVW - *Voltage Vector WEG*) que faz um controle da velocidade do motor com ajuste automático das variações de carga e rede. Este controle conta com algoritmos inseridos no software de controle que irão alterar a relação entre tensão e frequência para ajustar o torque.

Desta forma, a frequência de disparo do inversor se altera pela carga, portanto ao usinar uma peça, quanto menor o diâmetro desta, a frequência de disparo aumenta para manter o torque. Logo, as componentes de frequência relacionadas com disparo do inversor (frequência nominal de 5kHz) podem ser prejudiciais ao modelo por potencializarem a separação de dados de mesmo estado de desgaste, porém com diâmetros diferentes.

III. O MODELO DE PROGNÓSTICO DE FALHAS

A estrutura do modelo é apresentada na Figura 3. A base de dados utilizada nesse trabalho consiste em 592 séries temporais. Cada série temporal consiste em 750 medidas de tensão e corrente elétrica de cada uma das três fases do motor do torno, representado no diagrama pela matriz **R**. A base de dados é apresentada a um estágio de pré-processamento, onde ocorre a filtragem normalização da matriz, resultando na matriz **T**. O procedimento de pré-processamento adotado foi o mesmo exposto em [11].




Fig. 3. Modelo Proposto

Após o estágio de pré-processamento, a matriz **T** é apresentada ao algoritmo TSFRESH, que é responsável por extrair

os atributos de FFT de cada série temporal, assim como selecionar, através de teste de hipóteses, qual desses atributos é relevante para caracterizar a ocorrência de falhas. A saída do TSFRESH consiste em uma matriz \mathbf{I} .

Com a intenção de reduzir a dimensionalidade da matriz \mathbf{I} , foi aplicado o PCA. A saída do PCA, representada por \mathbf{J} , consiste na projeção dos dados da matriz \mathbf{I} em um novo sistema de coordenadas, formado por eixos chamados de Direções das Componentes Principais, que são calculados no começo do processo. O número de componentes principais utilizadas no decorrer do processo é fixo e previamente definido, os dados na matriz \mathbf{J} não podem ser diretamente relacionados à um sensor específico ou a um atributo específico extraído pelo TSFRESH, já que as Direções das Componentes Principais são calculadas pela variação dos dados, envolvendo todas as dimensões da matriz \mathbf{I} . O procedimento de redução de dimensionalidade adotado foi o mesmo exposto em [11].

Finalmente, os dados são apresentados ao módulo de classificação, onde a matriz \mathbf{J} é usada para treinar diferentes classificadores com a tarefa de classificar a condição da ferramenta de corte. Esses passos serão melhor discutidos na Seção IV-B.

A. Extração de Atributos Baseada em Testes de Hipóteses Escalonáveis (TSFRESH)

A extração de atributos é feita utilizando o algoritmo em Python TSFRESH, neste trabalho serão calculados os atributos relativos aos coeficientes da FFT, onde cada componente é representado pelo seu valor de magnitude e fase.

Considerando X um atributo calculado para uma das variáveis, com t_k , a k -ésima série temporal de \mathbf{T} , a relevância de X [12], [7] para a classificação Y é calculada a partir de sua função de distribuição acumulada, expressa como $F_{X|Y=y_1}$ e $F_{X|Y=y_2}$, onde y_1 e y_2 são o conjunto de valores para um atributo X calculado para as séries temporais de condição adequada e inadequada respectivamente. Assim, o atributo X é relevante para estimar Y se, e somente se:

$$\exists y_1, y_2 \text{ para } F_Y(y_1), F_Y(y_2) > 0 : F_{X|Y=y_1} \neq F_{X|Y=y_2} \quad (1)$$

A relevância também pode ser investigada através de testes de hipóteses [13]. O teste de hipóteses é independentemente aplicado ao atributo extraído X_i , em ordem de investigar as seguintes hipóteses:

$$\begin{aligned} H_0^i &= \{X_i \text{ não é relevante para } Y\}, \quad i = 1, 2, \dots, n; \\ H_1^i &= \{X_i \text{ é relevante para } Y\}, \quad i = 1, 2, \dots, n; \end{aligned} \quad (2)$$

onde n é o número de atributos extraídos e H_0^i e H_1^i são, respectivamente, a hipótese nula e a alternativa relacionada ao i -ésima atributo extraído, o resultado de cada teste é chamado de p -valor e corresponde à probabilidade de se obter uma estatística de teste igual ou mais extrema que aquela observada em uma amostra, baseada em hipótese nula.

O teste aplicado neste trabalho é o Teste de Kolmogorov-Smirnov (KS) [14], considerando as seguintes hipóteses:

$$\begin{aligned} H_0^i &= \{F_{X_i|Y=y_1} = F_{X_i|Y=y_2}\} \\ H_1^i &= \{F_{X_i|Y=y_1} \neq F_{X_i|Y=y_2}\} \end{aligned} \quad (3)$$

onde $F_{X_i|Y=y_1}$ é a função de distribuição acumulada (CDF) obtida pela integral da função densidade de probabilidade (PDF) de cada atributo X_i considerando os ensaios da ferramenta em condição adequada, já $F_{X_i|Y=y_2}$ é a CDF do atributo X_i considerando condição inadequada.

O teste de KS considera a diferença máxima entre as CDF's obtidas pelos atributos como pode ser visto na Equação 4.

$$D = \sup |F_{X_i|Y=y_1} - F_{X_i|Y=y_2}| \quad (4)$$

Contudo, a hipótese nula H_0^i é rejeitada se $D > D_{n,a}$, em que $D_{n,a}$ é um valor crítico do teste.

Finalmente, os atributos selecionados são concentrados na matriz $\mathbf{I}_{j \times n}$ onde n é o número de atributos selecionados e j é o número de séries temporais processadas.

IV. RESULTADOS EXPERIMENTAIS

Nessa seção, todos os algoritmos foram executados em um computador com processador Intel Core i7-8565U, frequência de clock de 4.60 GHz e 12 GB de RAM. A base de dados processada pelo modelo proposto é composta de 592 séries temporais normalizadas da tensão e corrente de cada uma das três fases do motor do torno. Cada série temporal é composta por 750 amostras. É importante ressaltar que 352 dessas séries temporais estão relacionadas a uma ferramenta em condição adequada e 240 a uma em condição inadequada. Devido às características do inversor mencionadas na Seção II, vale ressaltar que das 352 séries aquisitadas utilizando uma ferramenta em condição adequada, 240 foram ensaios usinando uma peça com diâmetro menor, partindo de 54mm enquanto 112 foram utilizando uma peça de diâmetro maior partindo de 78mm. Todos os ensaios com a ferramenta ruim foram feitos com um tarugo partindo de 78mm de diâmetro.

Com o objetivo de garantir robustez nos resultados, foi implementado o método de validação cruzada *KFold* utilizando 5 *folds* [15].

A. Análise de relevância dos atributos

Como a potência de corte tem ganhado bastante atenção na literatura, uma primeira análise considerando somente esse fator pode ser observada na Figura 4. Contudo, devido à presença do inversor de frequência no circuito, vemos que além da potência estar associada a classificação da ferramenta, ela também está associada ao diâmetro da peça sendo usinada.

Tendo em vista a influência do inversor, se torna necessária a extração de atributos da FFT com o TSFRESH. O TSFRESH executa a extração de 325 componentes da FFT, onde cada componente é representado pelo seu valor de magnitude e fase o que gera um total de 3900 atributos (3 fases \times 2 sensores por fase \times 325 componentes \times 2 valores), a seleção por teste de hipóteses resultou em uma média de 1000 atributos. O resultado do teste de hipóteses apontou a fase sendo irrelevante para a classificação. Esse resultado, está relacionado com a dessincronização das séries temporais.

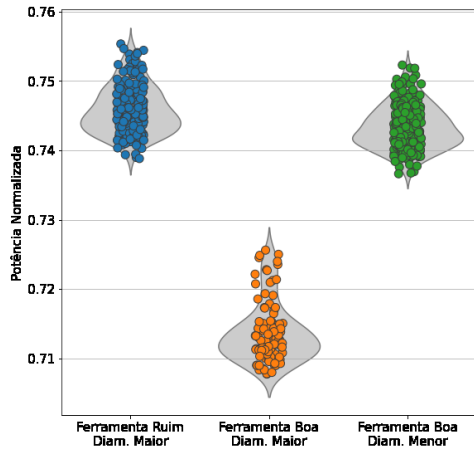


Fig. 4. Potência observada no motor do torno.

O PCA faz uma projeção das variáveis em componentes ortogonais independentes do atributo ou do sensor, cada componente principal pode ser representada como a projeção de diversas variáveis da base sem necessariamente ser relacionada à um sensor ou um atributo específico. Na Tabela I podemos ver que na composição das componentes principais temos uma maior variância para componentes de alta frequência. Na Figura 5 podemos ver a representação da base de dados em 3 Componentes Principais.

TABELA I
20 ATRIBUTOS COM MAIOR VARIÂNCIA.

Sensor	Coef.	Atributo	Sensor	Coef.	Atributo
Corrente C	142	Magnitude	Corrente B	323	Magnitude
Corrente A	142	Magnitude	Corrente C	306	Magnitude
Corrente B	305	Magnitude	Corrente C	167	Magnitude
Corrente B	151	Magnitude	Corrente B	4	Magnitude
Corrente A	305	Magnitude	Corrente A	4	Magnitude
Corrente B	142	Magnitude	Corrente C	305	Magnitude
Corrente A	306	Magnitude	Corrente B	295	Magnitude
Corrente C	4	Magnitude	Corrente B	162	Magnitude
Corrente C	162	Magnitude	Corrente C	146	Magnitude
Corrente B	306	Magnitude	Corrente A	151	Magnitude




Fig. 5. Base de dados projetada em 3 Componentes Principais.

É possível perceber que a maior influência dos atributos

de alta frequência resultaram em dois grupos de dados mais evidentes no espaço descrito pelas componentes principais. Estes grupos conseguem distinguir bem o diâmetro da peça que está sendo usinada, mas não a condição da ferramenta que é o principal objetivo do modelo. Portanto, foi aplicado às séries temporais um filtro de Butterworth passa baixa de ordem 4 e frequência de corte de 200Hz para manter a frequência da rede (60Hz) e eliminar as componentes de alta frequência. O diagrama de bode do filtro pode ser visto na Figura 6, assim como o exemplo de um dos sensores de uma série temporal utilizada no trabalho.

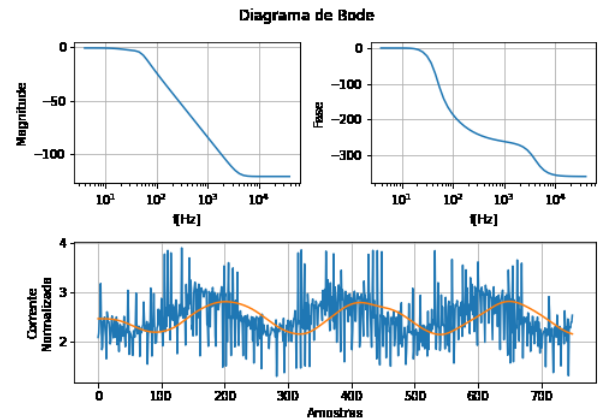


Fig. 6. Diagrama de Bode do Filtro, Sinal Original e Sinal Filtrado

Após a filtragem, podemos ver na Figura 7 a presença de três nuvens de dados, portanto a projeção exibe uma separação dos dados também em relação à condição da ferramenta. Considerando que o uso de mais componentes não aumentaria significativamente a informação mantida, apenas as primeiras 3 Componentes Principais foram utilizadas.

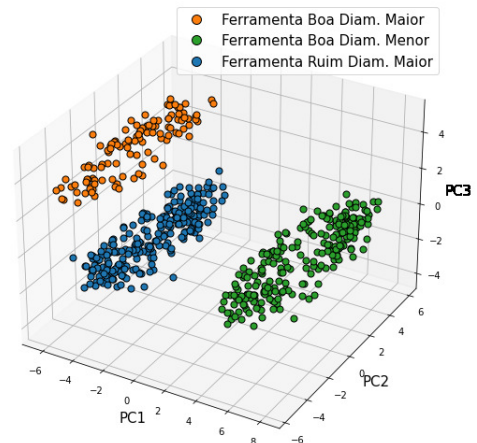


Fig. 7. Base de dados filtrada projetada em 3 Componentes Principais.

B. Classificação

Os classificadores implementados neste trabalho são baseados na biblioteca *Scikit-Learn* [9], uma biblioteca focada em inteligência computacional em Python. Mesmo com outras

configurações para os classificadores tendo sido testadas, a acurácia máxima foi obtida utilizando as configurações apresentadas no exemplo que se segue https://scikit-learn.org/stable/auto_examples/classification/plot_classifier_comparison.html, exceto para *Decision Tree*, *Random Forest* e *MLP Neural Network*. Os resultados obtidos por cada classificador estão expostos na Tabela II. Para uma melhor interpretação dos resultados da Tabela II, é importante ter em mente que o positivo na classificação representa uma ferramenta em condição inadequada de funcionamento.

TABELA II

RESULTADOS DE CLASSIFICAÇÃO PARA ACURÁCIA, PRECISÃO, RECALL E F1.

Classificadores	Acurácia [%]	Precisão [%]	Recall[%]	F1[%]
Nearest Neighbors	96.30 ± 7.39	94.48 ± 11.03	97.50 ± 5.00	95.85 ± 8.30
Linear SVM	96.13 ± 7.73	93.52 ± 12.96	100.00 ± 0.00	96.13 ± 7.73
RBF SVM	92.94 ± 12.87	100.00 ± 0.00	82.50 ± 31.91	85.68 ± 27.06
Gaussian Process	97.98 ± 4.03	96.43 ± 7.14	99.17 ± 1.67	97.69 ± 4.62
Decision Tree	97.98 ± 3.63	96.98 ± 6.04	98.33 ± 2.43	97.61 ± 4.27
Random Forest	98.32 ± 3.36	97.31 ± 5.38	98.75 ± 2.50	98.00 ± 4.00
Neural Net	97.98 ± 4.03	96.21 ± 7.59	99.58 ± 0.83	97.74 ± 4.53
AdaBoost	97.48 ± 4.63	97.08 ± 5.83	96.67 ± 5.68	96.87 ± 5.74
Naive Bayes	95.62 ± 7.12	93.94 ± 12.12	97.50 ± 2.43	95.28 ± 7.39
QDA	96.47 ± 7.06	94.29 ± 11.43	98.75 ± 2.50	96.22 ± 7.57

Nos classificadores *Decision Tree* e *Random Forest*, a profundidade máxima da árvore não foi definida, mas ramos são expandidos até que todas as folhas sejam puras, ou até que todas as folhas tenham menos que 2 amostras para evitar sobreajuste. Na *MLP Neural Network* o número máximo de iterações foi definido heurísticamente como 200.

Considerando o resultado dos classificadores, eles entregam uma performance acima de 92.94% em termos de acurácia. Já que a acurácia é uma proporção entre as classificações corretas sobre o número total de casos, esses resultados indicam que o modelo erra uma pequena quantia de eventos quando comparada com o número de classificações corretas.

O modelo alcança uma precisão acima de 93.52%, ou seja, ferramentas classificadas como inadequadas, são precisamente associadas com ferramentas inadequadas na maioria dos casos. Os resultados de recall são maiores que 82.50% em todos os classificadores, indicando a consistência em detectar as falhas na ferramenta de corte. Além do mais, a métrica F1 confira que os resultados satisfatórios de recall não afetam a precisão do modelo.

V. CONCLUSÃO

Este trabalho propõe uma abordagem para classificar ferramentas de corte de torno, durante um processo de usinagem, utilizando um filtro digital, a extração de atributos da FFT, seleção de atributos baseada em testes de hipóteses escalonáveis (TSFRESH), redução de dimensionalidade utilizando PCA e classificadores da biblioteca Scikit-Learn. O modelo alcançou resultados satisfatórios em termos de acurácia, precisão, recall e F1. Além disso, o modelo se mostra eficiente para identificar padrões que distinguem a condição de uma ferramenta de corte entre adequada e inadequada. Finalmente, o modelo proposto lida de forma eficiente com a sobreposição de estados de desgaste causada pelo acionamento do inversor de frequências WEG CFW500 no motor trifásico do torno.

Em trabalhos futuros, é planejado aplicar o modelo de previsão em um protótipo de baixo custo capaz de adquirir os dados e prever em tempo real a condição da ferramenta em ensaios exaustivos a fim de compreender diversos cenários de usinagem, incluindo um cenário intermediário pré-falha.

AGRADECIMENTOS

Os autores gostariam de agradecer a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Processo 433389 / 2018-4, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) - APQ-02922-18 e Universidade Federal de Juiz de Fora (UFJF) pelo suporte financeiro.

REFERÊNCIAS

- [1] Inc. Gardner Business Media. 2020 world machine tool survey shows machine tool downturn, 2021. <https://www.gardnerweb.com/blog/post/2020-world-machine-tool-survey-shows-machine-tool-downturn>, Acesso em: 2022-06-26.
- [2] Jr. Steven Kline. Pandemic continues machine tool industry downturn, but u.s. now a top 4 producer, 2021. <https://www.mmsonline.com/articles/pandemic-continues-machine-tool-industry-downturn-but-us-now-a-top-3-producer>, Acesso em: 2022-06-26.
- [3] D. Banjevic A. K. S. Jardine, D. Lin. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7):1483–1510, 2006.
- [4] R Keith Mobley. *An Introduction to Predictive Maintenance*. Butterworth-Heinemann, Woburn, MA, 2002.
- [5] A. Rastegari and M. Mobin. Maintenance decision making, supported by computerized maintenance management system. In *2016 Annual Reliability and Maintainability Symposium (RAMS)*, pages 1–8, Tucson, AZ, USA, 2016. IEEE.
- [6] E. D. Dimla. Sensor signals for tool-wear monitoring in metal cutting operations – a review of methods. *International Journal of Machine Tools Manufacture*, 40(8):1073–1098, 2000.
- [7] M. Christ, N. Braun, J. Neuffer, and A. W. Kempa-Liehr. Time series feature extraction on basis of scalable hypothesis tests (tsfresh – a python package). *Neurocomputing*, 307:72–77, 2018.
- [8] I. T. Jolliffe. *Principal Component Analysis and Factor Analysis*. Springer New York, New York, NY, 1986.
- [9] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12(85):2825–2830, 2011.
- [10] H. Shao, H. L. Wang, and X.M. Zhao. A cutting power model for tool wear monitoring in milling. *International Journal of Machine Tools and Manufacture*, 44(14):1503–1509, 2004.
- [11] Miranda Guilherme P. C. de Alexandre F. Dutra Matheus P. Antunes Marcos V. G. R. da Silva Eduardo P. de Aguiar Thiago E. Fernandes, Matheus A. M. Ferreira. Classification of lathe’s cutting tool wear based on an autonomous machine learning model. *Journal of Control, Automation and Electrical Systems*, 33(1):167–182, 2022.
- [12] P. Radivojac, Z. Obradovic, A. K. Dunker, and S. Vucetic. Feature selection filters based on the permutation test. 3201:334–346, 2004.
- [13] M. Christ, A. W. Kempa-Liehr, and M. Feindt. Distributed and parallel time series feature extraction for industrial big data applications. *CoRR*, abs/1610.07717, 2016.
- [14] R. Wilcoxon. Kolmogorov–smirnov test. *Encyclopedia of biostatistics*, 2005.
- [15] Ron Kohavi. A study of cross-validation and bootstrap for accuracy estimation and model selection. page 1137–1143, 1995.