



## APLICAÇÕES DE TÉCNICAS DE REGRESSÃO PARA O MONITORAMENTO DE CONDIÇÕES DE MÁQUINAS NO CONTEXTO INDUSTRIAL

SILVA, G. R.<sup>1</sup>; COSME, L. B.<sup>2</sup>

<sup>1</sup>Discente do curso superior em ciência da computação do IFNMG – *Campus* Montes Claros;

<sup>2</sup>Docente do IFNMG – *Campus* Montes Claros.

### Introdução

No contexto da manutenção industrial, o monitoramento da condição de máquinas constitui uma etapa crucial da manutenção preditiva, visando determinar a vida útil remanescente dos equipamentos. Esse acompanhamento é importante e necessário, uma vez que visa prevenir paralisações inesperadas, minimizar perdas de materiais, além de potencialmente evitar acidentes que possam resultar em lesões pessoais. (COSME, 2018).

Entretanto, ainda há barreiras que dificultam a implementação nesse contexto industrial, como a grande quantidade e qualidade de dados necessários, a compreensão física dos equipamentos e a complexidade dos modelos para a indústria (SIKORSKA, 2012). Dada as questões mencionadas, o presente estudo empregou abordagens de monitoramento, que podem ser consideradas menos complexas, com o objetivo de obter métricas satisfatórias, mas levando em consideração a simplicidade desses métodos para aplicações práticas.

### Material e Métodos

O presente estudo seguiu a metodologia de trabalho descrita na Figura 1. Como fonte de dados, foram utilizados a base de dados da *PHM society conference data challenge 2010*, que fornece dados reais de fresadoras com controle numérico computadorizado (do inglês, *Computer Numeric Control* - CNC) de alta velocidade. A **aquisição de dados** coletou informações de dinamômetro, acelerômetro e captador de emissão acústica. Esses sensores estão presentes na Figura 2. Os dados são de três máquinas fresadoras CNC, compostos de cerca de 300 arquivos com 8 colunas cada, sendo uma delas o nível de degradação do equipamento medido em laboratório.

Durante a etapa de **pré-processamento dos dados**, foi realizado um processo de extração de características, que gerou 18 variáveis com 315 instantes de tempo (linhas) para cada máquina. Além disso, tem-se um limite de  $150.10^{-3}mm$  para o desgaste das três fresas, sendo o instante em que se alcança esse limiar o momento da falha. Uma normalização *z-score* foi aplicada aos dados pré-processados.

Para a **seleção de características**, uma variável alvo que simula uma degradação linear da máquina foi criada, utilizando a diferença entre os valores máximo e atual, dado cada instante. Dois métodos foram usados na tentativa de obter variáveis representativas, a partir dos dados de sensores, do estado atual da máquina. No primeiro método, utilizou-se o coeficiente de Pearson, no qual foram selecionadas as quatro características mais correlacionadas com a variável alvo. Como segundo método, a análise de componentes principais (do inglês, *principal component analysis* - PCA) foi empregada, obtendo quatro componentes principais que explicam 95% da variância dos dados.

O **treinamento dos modelos** de monitoramento usou regressão linear múltipla, regressão linear múltipla com PCA e regressão polinomial múltipla (MONTGOMERY, 2009). Devido à pequena quantidade de dados disponíveis, três experimentos foram desenvolvidos utilizando cada



técnica e repetindo a etapa de seleção de características conforme descrito anteriormente. Para o treinamento dos modelos, o primeiro experimento utiliza as máquinas 1 e 4, o segundo usa as máquinas 1 e 6 e o terceiro experimento as máquinas 4 e 6. Em cada situação, a máquina não usada no treinamento constitui os dados de validação, nas quais foram submetidas as métricas de avaliação coeficiente de determinação ( $R^2$ ) (MONTGOMERY, 2009) e cone de acurácia (COSME et al, 2019).

## Resultados e Discussão

Os resultados do  $R^2$  estão presentes na Tabela 1, que mostra a validação dos três experimentos (CNC 1, significa que foram usados os dados das máquinas 4 e 6 para treinamento) e para os três modelos. A regressão polinomial múltipla obteve a melhor performance para todas as máquinas, quando comparada aos outros experimentos. As quatro características selecionadas no treinamento deste modelo foram, *stdNZ*, *rmsNZ*, *picoNZ* e *picoNY*, que representam o desvio padrão da força no eixo Z, raiz quadrada média da força no eixo Z, pico de força no eixo Z e pico de força no eixo Y respectivamente. Apesar do uso das mesmas variáveis no experimento de regressão linear múltipla, pode-se observar um resultado inferior, levantando suposições da incapacidade de um ajuste aos dados não lineares. Para a métrica do cone de acurácia, que mede a proporção dos resultados dentro do intervalo de 20% da variável alvo, obteve-se um bom resultado para dois dos experimentos, com 60% e 78% dos valores dentro do intervalo. Entretanto, para a validação com a máquina 6 (CNC 6) o resultado foi de 19%.

## Considerações finais

Os resultados apresentados neste resumo constituem uma etapa inicial de análise desses dados. A metodologia empregada busca a aplicação de modelos mais simples que consigam projetar de forma concisa a degradação de equipamentos e que possam ser empregadas em um contexto real. De forma geral, as técnicas de regressão, que já são amplamente utilizadas, se mostraram promissoras. Para trabalhos futuros, pretende-se realizar uma busca minuciosa para ajuste dos modelos e também realizar um estudo mais aprofundado das características dos dados, que guiarão as etapas seguintes do projeto.

## Agradecimentos

Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e apoiado pela Fundação de Apoio e Desenvolvimento do Ensino Tecnológico (FADETEC) e Instituto Federal do Norte de Minas Gerais (IFNMG) Campus Montes Claros.

## Referências

- COSME, L. B. **Propostas de Novas Técnicas para o Problema de Prognóstico de Falhas em Sistemas Dinâmicos**. 2018. 116 f. Tese (Doutorado em Engenharia Elétrica) - Escola de Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2018.
- COSME, L. B. et al. A Novel Fault-Prognostic Approach Based on Interacting Multiple Model Filters and Fuzzy Systems. **Ieee Transactions On Industrial Electronics**, [S.L.], v. 66, n. 1, p. 519-528, jan. 2019. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tie.2018.2826449>.
- DAI, W.; LIANG, K.; WANG, B.. State Monitoring Method for Tool Wear in Aerospace Manufacturing Processes Based on a Convolutional Neural Network (CNN). **Aerospace**, [S.L.], v. 8, n. 11, p. 335, 8 nov. 2021. MDPI AG. <http://dx.doi.org/10.3390/aerospace8110335>.
- PHM SOCIETY. **2010 PHM Society Conference Data Challenge**. 2010. Página inicial. Disponível em: <[https://phmsociety.org/phm\\_competition/2010-phm-society-conference-data-challenge/](https://phmsociety.org/phm_competition/2010-phm-society-conference-data-challenge/)>. Acesso em: 08 set. 2023.



LUO, W. et al. A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. **Robotics And Computer-Integrated Manufacturing**, [S.L.], v. 65, p. 101974, out. 2020. Elsevier BV.

<http://dx.doi.org/10.1016/j.rcim.2020.101974>.

MATHWORKS. **Designing Algorithms for Condition Monitoring and Predictive Maintenance**, c2023. Página inicial. Disponível em: <<https://www.mathworks.com/help/predmaint/gs/designing-algorithms-for-condition-monitoring-and-predictive-maintenance.html>>. Acesso em: 08 set. 2023.

MONTGOMERY, D. C.; GEORGE. C. R. **Estatística aplicada e probabilidade para engenheiros**. 4. ed. [S.I.]: Ltc, 2009.

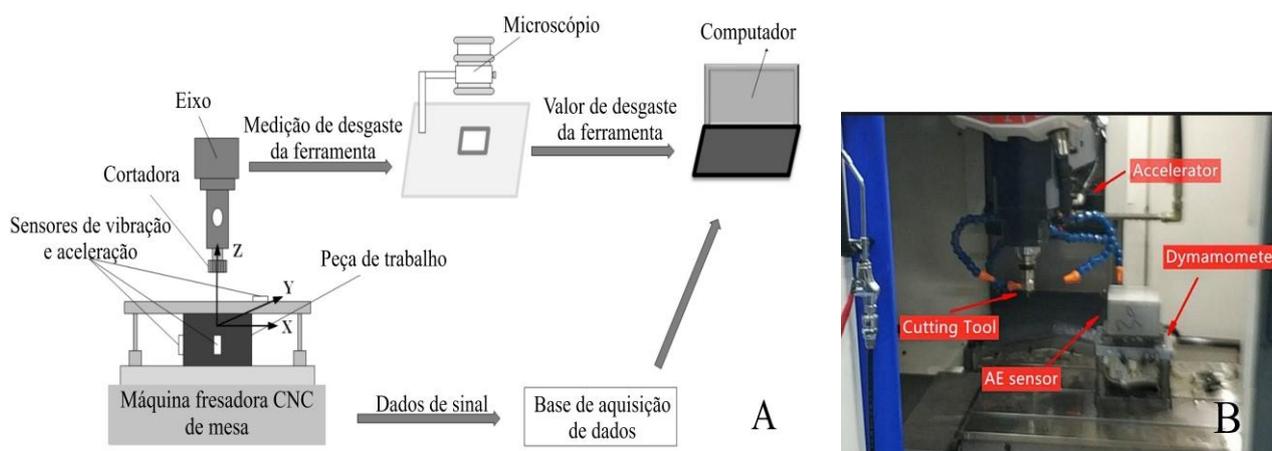
SIKORSKA, J. Z.; HODKIEWICZ, M.; MA, L. Prognostic modelling options for remaining useful life estimation by industry. **Mechanical Systems And Signal Processing**, [S.L.], v. 25, n. 5, p. 1803-1836, jul. 2011. Elsevier BV.

<http://dx.doi.org/10.1016/j.ymsp.2010.11.018>.

### Figuras e tabelas:



**Figura 1.** Metodologia aplicada no trabalho. Fonte: Acervo do autor (2023)



**Figura 2.** (A) Estrutura experimental do *PHM society conference data challenge 2010*. Fonte: Traduzido pelo autor. DAI (2021).

(B) Máquina fresadora CNC com posicionamento dos sensores. Fonte: LUO (2020)

**Tabela 1.** Resultados obtidos para a validação dos três experimentos (CNC 1, significa que foram usados os dados das máquinas 4 e 6 para treinamento) e para os três modelos

	$R^2$ reg. linear múltipla	$R^2$ reg. linear com PCA	$R^2$ reg. polinomial
CNC 1	0.83	0.75	0.87
CNC 4	0.89	0.90	0.91
CNC 6	0.32	0.36	0.42

Fonte: Acervo do autor (2023).