

Reconhecimento de Padrão Vibracional de Lubrificantes utilizando Sistemas Imunológicos Artificiais

Fábio R. Chavarette¹; Henrique A. M. Faria²; Jorge M.V.Capela³; Marisa V.Capela⁴
UNESP, IQ, DEFM Araraquara, SP
Roberto Outa⁵
FATEC, Lins, SP
Aparecido C. Gonçalves⁶; Guido A. Slavec⁷
UNESP, FEIS, DEM Ilha Solteira, SP

Resumo.

A maioria dos sistemas mecânicos utiliza a lubrificação para seu correto funcionamento. Para a indústria, a identificação e a caracterização de sinais vibracionais nesses sistemas são fundamentais e, ao mesmo tempo, desafiadoras. Para oferecer uma alternativa ao monitoramento de sinais vibracionais, este trabalho propõe a utilização do Sistema Imunológico Artificial (SIA) baseado no Algoritmo de Seleção Negativa como ferramenta de análise. O SIA é capaz de distinguir os sinais de vibrações de uma estrutura mecânica com lubrificante mineral ou lubrificante vegetal, contribuindo para a nova indústria 4.0. A proposta de monitoramento pode contribuir para a melhoria do funcionamento das máquinas industriais e para a preservação da estrutura interna dos equipamentos.

Palavras-chave. Computação Inteligente, Vibrações, Algoritmo de Seleção Negativa

1 Introdução

O reconhecimento de padrões consiste em uma tarefa de classificação ou categorização dos sinais monitorados em sistemas mecânicos. A engenharia de manutenção considera dois tipos de classificação: a classificação supervisionada e a classificação não supervisionada, sendo esta última determinada com base nas semelhanças dos padrões dos sinais recebidos. Atualmente, o reconhecimento de padrões tem sido cada vez mais pesquisado devido às diversas aplicações. No entanto, esse reconhecimento é desafiador e exige grandes esforços computacionais.

A disponibilidade de recursos computacionais avançados está transformando o uso e a elaboração de métodos para a análise de reconhecimento de padrões. Um sistema de reconhecimento de padrões contém três etapas principais, conforme segue: aquisição de dados, que consiste na extração de características e no pré-processamento discriminativo; representação de dados; e tomada de decisão, que, computacionalmente, significa a construção de um classificador.

A principal contribuição no reconhecimento de padrões, presente na literatura especializada, é a construção de métodos de classificação baseados em sistemas inteligentes, como lógica fuzzy [7], redes neurais artificiais [4] e sistemas imunológicos artificiais [1], entre outros.

¹fabio.chavarette@unesp.br

²henrique.faria@unesp.br

³jorge.capela@unesp.br

⁴marisa.capela@unesp.br

⁵roberto.outa@gmail.com

⁶cido@dem.feis.unesp.br

⁷guidoslavec@gmail.com

Nos últimos anos, o reconhecimento de padrões tem sido introduzido no setor industrial como uma ferramenta para o monitoramento e controle de qualidade de produtos, processos e manutenção preditiva de máquinas. Essa estratégia da indústria 4.0 melhora os indicadores de eficiência operacional e oferece produtos cada vez mais competitivos no mercado. Atualmente, os insumos energéticos renováveis, como bioetanol, biodiesel e biomassa, vêm sendo utilizados no setor industrial por suas vantagens sobre os combustíveis fósseis. Os bio-lubrificantes tornaram-se uma alternativa viável frente aos lubrificantes à base de petróleo para diferentes aplicações, especialmente na nova indústria automotiva [5].

2 Procedimento Experimental

Para o desenvolvimento deste trabalho, foi utilizada uma bancada experimental com a finalidade de obter um conjunto de dados, os quais foram utilizados para a aplicação na classificação de lubrificantes. Para verificar a eficiência da biograxa sintetizada, foi empregada a análise de vibração por lubrificante. Os ensaios foram realizados em uma bancada experimental [3] do tipo pin on disk através do tribômetro, ilustrado na Figura 1. Destaca-se, na Figura 1a, a vista frontal do equipamento, e, na Figura 1b, sua vista lateral.

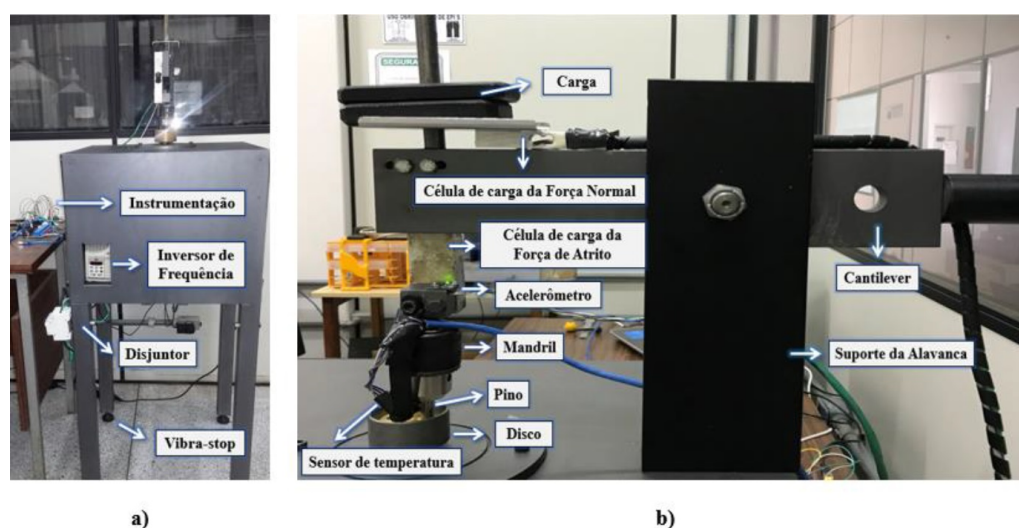


Figura 1: *Pin-on-disk*: a) vista frontal e b) vista lateral do tribômetro. Fonte: dos autores.

Além disso, a Figura 2 destaca os componentes elétricos e eletrônicos utilizados na instrumentação do equipamento de monitoramento. Segundo [3], essa instrumentação é de baixo custo e é controlada por meio de uma plataforma com código aberto, como o Arduino.




Figura 2: Componentes elétricos e eletrônicos utilizados no tribômetro. Fonte: dos autores

3 Metodologia Proposta

O sistema inteligente baseado no Algoritmo de Seleção Negativa (ASN) foi desenvolvido para a classificação dos dados e possui três módulos: a aquisição de dados, o sensoriamento e o monitoramento do algoritmo de seleção negativa [2].

No módulo de aquisição dos dados, os resultados foram obtidos por meio da bancada experimental ilustrada na Figura 1. Esses dados foram utilizados nas fases de sensoriamento e monitoramento do sistema imune artificial.

No módulo de sensoriamento, realiza-se o censo dos dados, criando um conjunto de detectores para identificar as anomalias no processo de monitoramento. Esse processo é realizado de forma off-line.

Por fim, no módulo de monitoramento, os sinais dos lubrificantes são detectados por meio da avaliação e verificação do casamento com o conjunto de detectores próprios (sinais base-line). Assim, realiza-se a detecção de sinais com base na discriminação entre sinais próprios e não-próprios. Caso o sinal identificado seja próprio, ele é classificado instantaneamente como a condição normal. Caso contrário, o sinal representa uma condição anormal, denominada de não-próprio. Portanto, nesta fase, os dados são analisados em tempo real, sendo comparados com o conjunto de detectores criados na fase de sensoriamento. Assim, um diagnóstico é apresentado, e a tomada de decisão é orientada pela discriminação entre os dois tipos de sinais: próprio ou não-próprio. O monitoramento dos sinais é realizado de forma online.

A Figura 3 mostra o fluxograma do algoritmo de seleção negativa nas fases de sensoriamento e monitoramento.

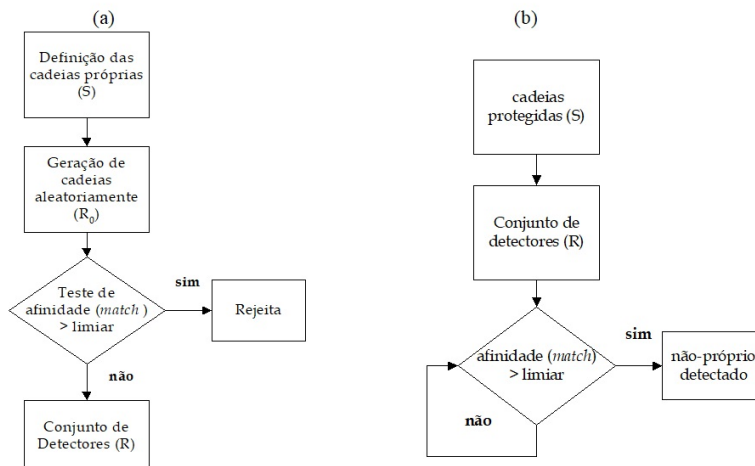


Figura 3: Fluxograma das fases de (a) sensoriamento e (b) monitoramento do Algoritmo de Seleção Negativa. Fonte: dos autores.

4 Aplicação e Resultados

O experimento ilustrado nas Figuras 1 e 2 subsidiou a montagem de um banco de dados com 450 sinais baseline originados de lubrificante de base mineral e 450 sinais provenientes dos bio-lubrificantes, totalizando 900 sinais. Os sinais analisados consideram apenas o primeiro pacote (first packet), que corresponde à parte do sinal que melhor representa as alterações no comportamento. Cada sinal foi representado por 200 pontos. Este estudo de reconhecimento de padrões visa classificar os lubrificantes quanto à similaridade das vibrações em tempo real.

Foram realizados três testes com a finalidade de avaliar a metodologia proposta no processo de análise e classificação dos dados. A eficiência do sistema em relação às diferentes configurações do conjunto de detectores do algoritmo de seleção negativa foi verificada. Esses testes forneceram as informações que representam o conhecimento do sistema. Para um melhor reconhecimento dos sinais por parte do algoritmo de seleção negativa, foram adotadas taxas de afinidade de 70%, 80% e 90%, desvio padrão de 3% e uma população variada. Os testes realizados estão descritos na Tabela 1.

Tabela 1: Descrição dos testes realizados.

Testes	Total de Sinais	Sinais Base Mineral	Sinais Bio-lubrificante
1	900	450	450
2	500	250	250
3	300	150	150

As classificações quanto a similaridade dos padrões de vibração obtidas por meio do algoritmo de seleção negativa estão ilustrados na Tabela 2.

Tabela 2: Taxa de acertos obtidos nos testes realizados.

Testes	Acerto de Similaridade (%)
1	99.9
2	99.1
3	98.3

Pode-se observar na Tabela 2 que o sistema de análise de reconhecimento de padrões, aplicado ao biolubrificante, apresenta um bom desempenho, com índice de acerto de similaridade dos sinais de 99.9% na melhor configuração, em relação ao lubrificante de base mineral. Observou-se que a quantidade de detectores influencia diretamente o processo de diagnóstico do biolubrificante. Dessa forma, sugere-se utilizar 30% das informações do conjunto de dados para gerar o conjunto de detectores, visando proporcionar uma maior robustez ao sistema. Quanto mais conhecimento disponível, mais eficiente se torna o processo de diagnóstico do ASN.

Por fim, destaca-se que o sistema proporciona aplicação em tempo real, favorecendo a tomada de decisões em tempo hábil para melhorar o desempenho dos sistemas mecânicos em funcionamento.

5 Considerações Finais

Neste trabalho, foi possível obter um acerto de similaridade mínima de 98.3% e máxima de 99.9%. Nota-se que a quantidade de detectores influencia diretamente no processo de diagnóstico de padrões, conforme os parâmetros estabelecidos por [6]. Logo, é possível concluir que o algoritmo de seleção negativa expressa precisão e confiabilidade quando atendidos os parâmetros de desvio menores que 3% e uma quantidade de detectores equivalente a 30% dos dados.

Pode-se concluir, a partir dos resultados dos testes experimentais, que quanto mais conhecimento o algoritmo de seleção negativa obtém na fase de censuriamento, mais eficiente se torna o processo de reconhecimento e classificação. Assim, a ferramenta verificou a afinidade entre os sinais de lubrificantes de base mineral e de base vegetal, indicando que é possível a substituição do lubrificante de base fóssil por um lubrificante de base vegetal.

Agradecimentos

Agradecemos à UNESP (Universidade Estadual Paulista) pela infraestrutura fornecida e pelas atividades de coleta de dados desenvolvidas no Laboratório de Sistemas Complexos. Agradecemos ao CNPq e à FAPESP pelo apoio e incentivo às pesquisas desenvolvidas: CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico (Proc. N. 301401/2022-5) e FAPESP – Fundação de Amparo à Pesquisa de São Paulo (Proc. n. 2023/00861-8).

Referências

- [1] L. N. de Castro. “Immune engineering: development and application of computational tools inspired by artificial immune systems”. Tese de doutorado. UNICAMP, 2001.
- [2] S. A. Forrest, A. L. Perelson e R. Cherukuri. “Self-nonsel self discrimination in a computer”. Em: **Proceedings of the IEEE Symposium on research in security and privacy**. 1994, pp. 202–212. ISBN: 9788529402024. DOI: 10.1109/RISP.1994.296580.

- [3] C. F. F. Galvão, G. A. Slavec, P. L. de A. Menardi, A. C. Gonçalves, F. R. Chavarette e R. Outa. “Design and construction of a pin-on-disk experimental bench to determine the friction coefficients of materials”. Em: **ABCM International Congress of Mechanical Engineering**. 2019, s. n.
- [4] S. Haykin. **Neural networks: a comprehensive foundation**. Upper Saddle. New Jersey: USA: Prentice-Hall, 1994. ISBN: 0132733501.
- [5] E. K. Heikal, M. S. Elmelawy, S. A. Khalil e N. M. Elbasuny. “Manufacturing of Environment Friendly Biolubricants from Vegetable Oils”. Em: **Egyptian Journal of Petroleum** 26 (2017), pp. 53–59. DOI: [j.ejpe.2016.03.003](https://doi.org/10.1016/j.ejpe.2016.03.003).
- [6] F. P. A. Lima, F. R. Chavarette, S. S. F. Souza, A. S. E. Souza e M. L. M. LOPES. “Artificial immune systems applied to the analysis of structural integrity of a building.” Em: **Applied Mechanics and Materials** 472 (2014), pp. 544–549. DOI: [10.4028/www.scientific.net/AMM.472.544](https://doi.org/10.4028/www.scientific.net/AMM.472.544).
- [7] L. A Zadeh. “Fuzzy sets. Information and Control”. Em: **The Journal of Symbolic Logic** 38 (1973), pp. 656–657. DOI: [10.2307/2272014](https://doi.org/10.2307/2272014).