

Uma Nova Abordagem para Classificação de Falhas baseada em Árvores de Decisão Induzidas por Programação Genética

Rogério C. N. Rocha¹Rafael A. Soares²Gabriel F. F. Cardoso³

PPGMCS/UNIMONTES, Montes Claros, MG

Laércio I. Santos⁴

IFNMG, Montes Claros, MG

Marcos F. V. D'Angelo⁵

DCC/UNIMONTES, Montes Claros, MG

Este estudo apresenta uma metodologia em duas etapas para Detecção e Diagnóstico de Falhas (FDD). Na primeira etapa, aborda-se a detecção de pontos de mudança em séries temporais, utilizando uma abordagem *fuzzy/Bayesiana* [2] para tratar o problema como detecção de falhas. A probabilidade resultante de mudança é então aplicada na segunda etapa, o diagnóstico de falhas, que emprega uma abordagem baseada em árvores de decisão induzidas por programação genética. Este estudo aprimora o modelo original de árvore de decisão proposto por [4] para lidar com problemas multiclasse, incorporando uma estratégia que envolve a evolução simultânea de múltiplas populações paralelas. A avaliação do *framework* proposto para FDD foi conduzida no *benchmark Tennessee Eastman* [3], comparando seu desempenho com métodos convencionais como PCA e SVM, conforme proposto por [1]. A Tabela 1 apresenta a acurácia dos métodos para as 21 falhas a que o *benchmark Tennessee Eastman* está sujeito, demonstrando que a metodologia proposta superou os métodos Análise de Componentes Principais (PCA) e Máquina de Vetores de Suporte (SVM). Esta melhoria ressalta a versatilidade e superioridade da abordagem proposta na classificação de falhas em cenários complexos. O *framework* é composto por dois módulos principais: detecção de ponto de mudança e classificação de falhas, conforme ilustrado na Figura 1.

Tabela 1: Comparação de resultados.

Categoria	Falha 1	Falha 2	Falha 3	Falha 4	Falha 5	Falha 6	Falha 7	Falha 8	Falha 9	Falha 10	Média
Metodologia Proposta	99.27%	96.43%	50.67%	67.16%	97.45%	94.33%	93.17%	98.66%	9.84%	94.95%	80.32%
PCA	87.19%	87.50%	18.33%	72.71%	4.06%	90.21%	89.69%	85.00%	20.00%	76.15%	67.20%
SVM	87.19%	85.83%	15.21%	49.48%	50.60%	78.85%	88.85%	32.19%	12.00%	22.60%	41.26%
	Falha 11	Falha 12	Falha 13	Falha 14	Falha 15	Falha 16	Falha 17	Falha 18	Falha 19	Falha 20	Falha 21
Metodologia Proposta	74.37%	98.73%	91.78%	86.80%	88.94%	75.81%	90.06%	62.58%	89.15%	80.84%	45.78%
PCA	65.42%	85.83%	69.06%	86.56%	23.02%	69.48%	74.48%	59.90%	84.06%	77.50%	85.00%
SVM	11.88%	50.21%	21.46%	54.90%	18.85%	12.81%	48.02%	32.19%	46.25%	38.96%	8.23%

¹rogeriocostanegro@hotmail.com

²rafael.almeida.soares2012@gmail.com

³gabrielffcardoso@gmail.com

⁴laercio.ives@gmail.com

⁵marcos.dangelo@unimontes.br

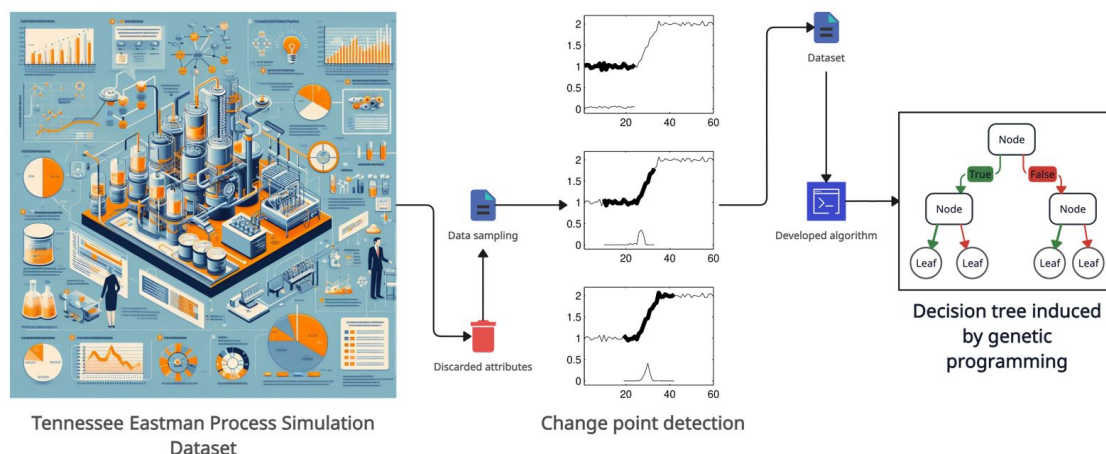


Figura 1: Framework FDI proposto. Fonte: dos autores.

Agradecimentos

Os autores agradecem ao CNPq, CAPES e FAPEMIG.

Referências

- [1] C. Jing e J. Hou. “SVM and PCA based fault classification approaches for complicated industrial process”. Em: **Neurocomputing** 167 (2015), pp. 636–642.
- [2] M. F. S. V. D’Angelo, R. M. Palhares, R. H. C. Takahashi, R. H. Loschi, L. M. R. Baccarini e W. M. Caminhas. “Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach”. Em: **Applied Soft Computing** 11(1) (2011), pp. 179–192.
- [3] J. Downs e E. Vogel. “A plant-wide industrial process control problem”. Em: **Computers & Chemical Engineering** 17(3) (1993), pp. 245–255.
- [4] L. I. Santos, M. O. Camargos, M. F. S. V. D’Angelo, J. B. Mendes, E. E. C. de Medeiros, A. L. S. Guimarães e R. M. Palhares. “Decision tree and artificial immune systems for stroke prediction in imbalanced data”. Em: **Expert Systems with Applications** 191 (2022), p. 116221.