

Detecção e Isolamento de Falhas em Sistemas Complexos: Um Mapeamento Sistemático da Literatura

Marcelo Alexandre Martins da Conceição¹, André Benzi Baccarin¹, Oswaldo Segundo da Costa Neto¹, Adilson Marques da Cunha¹, Leonardo Ramos Rodrigues²

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

²Instituto de Aeronáutica e Espaço (IAE), São José dos Campos/SP – Brasil

Resumo—A área de manutenção vem exercendo papéis estratégicos em organizações, sejam automobilísticas, industriais ou militares. Com avanços das capacidades de geração, armazenamento e processamento de dados, técnicas de Aprendizado de Máquina (AM) vêm sendo empregadas para detectar e localizar falhas em sistemas complexos, aumentando a disponibilidade e reduzindo custos operacionais desses sistemas. Porém, simplesmente aplicar técnicas de AM aos dados de sensores não vem representando uma solução para todos problemas, uma vez existem barreiras ainda a serem transpostas. O objetivo deste artigo é apresentar um mapeamento sistemático da literatura sobre métodos de AM aplicados à detecção e isolamento de falhas em sistemas complexos, por meio de uma abordagem dirigida a dados *Data-Driven*. Com essa abordagem, pretende-se propiciar uma melhor compreensão de como métodos propostos vêm abordando cenários realísticos de sistemas complexos, em que novos modos de falhas podem surgir após a construção inicial de modelos de AM.

Palavras-Chave—Detecção e Isolamento de Falhas, *Data-Driven Approach*, Aprendizado de Máquina, Manutenção.

I. INTRODUÇÃO

Em uma Força Aérea, a logística por meio da manutenção de aeronaves vem se tornando essencial para a obtenção de vantagens operacionais em conflitos armados.

A manutenção possui potencial de geração de valores para organizações militares, evitando inatividades por panes de equipamentos aéreos, estendendo a vida útil de sistemas aeronáuticos, reduzindo o número de horas requeridas para se completar manutenções e antecipando eventos críticos com potenciais perdas bélicas e econômicas.

Pode-se inferir que, quanto mais rápidas as detecções e os diagnósticos de falhas em sistemas, subsistemas e/ou componentes, mais eficientes tornam-se as atividades de manutenção, migrando-se, então, de cenários reativos para proativos [1].

Nesse sentido, diversos métodos vêm sendo propostos para otimizar as etapas de detecções e isolamentos de falhas (*Fault Detection and Isolation* - FDI) em sistemas complexos, em que, aparentemente ocorrem certa aleatoriedade na degradação de ativos durante sua vida útil, uma vez que o desgaste de equipamentos sofre influência do modo de operação, de efeitos ambientais e de diversos outros fatores [2].

Para implementar um sistema de FDI, métodos vêm sendo propostos baseados em 3 abordagens: *Model-Based*, *Data-Driven* e Híbrida [3]. A abordagem baseada em modelo

(*Model-Based*) se utiliza de modelos matemáticos da dinâmica dos componentes, baseando-se na compreensão física ou determinística do sistema, dependendo fortemente da precisão dos modelos criados [4].

A abordagem dirigida por dados (*Data-Driven*) não utiliza a compreensão física do sistema em estudo, porém o comportamento é aprendido com base em dados coletados de sensores, o que gera a necessidade de grandes volumes de dados para que seja possível se criar modelos preditivos e descritivos [5]. Por último, a abordagem Híbrida é baseada em características das duas primeiras.

Com o avanço da área de grandes conjuntos de dados (*Big Data*), as atividades de manutenção, reparo e operações passaram a se beneficiar sobremaneira. Aeronaves modernas costumam gerar Terabytes (TB) de dados de manutenção por hora de voo [6], que podem ser utilizados para o monitoramento de condições de sistemas complexos, por meio da abordagem *Data-Driven*.

A maioria dos trabalhos disponíveis na literatura baseia-se em premissas não realistas para ambientes operacionais reais e complexos como cenários controlados, conhecimento prévio da dinâmica de ativos e utilização de dados históricos completamente rotulados.

Na maioria das aplicações reais, essas premissas não vêm sendo observadas, principalmente quando o objetivo é o de se definir, previamente, modos de falha de ativos para treinamentos de modelos de aprendizado de máquina, em se tratando da abordagem *Data-Driven*.

Pelas características dinâmicas inerentes aos sistemas complexos, modos de falha podem surgir após a fase de *design* de um ativo, não sendo mapeados por métodos tradicionais como o FMEA (*Failure Mode and Effects Analysis*), impossibilitando mapeá-los *a priori*, pois tais falhas surgem apenas após meses, anos ou décadas de operação de ativos.

Dessa forma, o presente artigo tem por objetivo mapear estudos primários que possuem como premissas características de operações reais, utilizando a abordagem *Data-Driven* e estratégias dinâmicas para considerar novos modos de falha em sistemas complexos.

O restante deste artigo encontra-se estruturado da seguinte forma. A Seção II descreve o planejamento do Mapeamento Sistemático da Literatura (MSL). A Seção III apresenta um breve referencial teórico para compreensão dos principais conceitos acerca da temática. A Seção IV explana os principais resultados obtidos e, por fim, a Seção V conclui o artigo com algumas considerações consideradas relevantes.

II. PLANEJAMENTO DO MAPEAMENTO SISTEMÁTICO DA LITERATURA

Com o objetivo de identificar artigos publicados que propuseram, por meio da abordagem *Data-Driven*, soluções para superar o problema descrito anteriormente, esta seção apresenta a metodologia utilizada para um Mapeamento Sistemático da Literatura (MSL), adaptado de [7].

Com base no objetivo delineado na Seção I, a seguinte **questão de pesquisa** foi definida: “*Quais características de problemas, métodos, experimentos e soluções vêm sendo reportados e propostos para tratar de detecções e isolamentos de falhas por meio da abordagem Data-Driven, no contexto de modos de falha não mapeados previamente, aplicando técnicas de Aprendizado de Máquina?*”.

Objetivando transformar a questão de pesquisa em uma *string* de busca coerente e completa, foi utilizada a seguinte estratégia de busca baseada em perguntas estruturadas denominada PICO (População, Intervenção, Comparação e Resultado - *Outcome*) [7]:

- **População** - que publicações relacionadas à técnicas de FDI podem ser encontradas usando-se a abordagem *Data-Driven* no contexto de modos de falhas não previstos inicialmente;
- **Intervenção** - que métodos podem ser encontrados aplicando-se técnicas de Aprendizado de Máquina (AM) para a detecção e o isolamento de falhas (*Fault Detection and Isolation* - FDI);
- **Comparação** - não aplicável neste contexto; e
- **Resultado** - que identificação de características de problemas e métodos podem ser propostos para solucionar o surgimento de novos modos de falhas, durante a fase de operação de sistemas complexos.

Para este MSL, foi realizada uma busca automática nas seguintes bases bibliográficas relevantes para a Ciência da Computação: *IEEE Explore*; *ISI Web Of Science*; *ScienceDirect*; *Scopus* e *SpringerLink* [7].

Em cada base bibliográfica, foi derivada a *string* de busca base ilustrada na Fig. 1, onde “fdd”, “fdi” e “cm” significam, respectivamente, *Fault Detection and Diagnosis*, *Fault Detection and Isolation* e *Condition Monitoring*, e os marcadores “P” e “I” indicam, respectivamente, as palavras-chave **População** e **Intervenção** do critério PICO.

```
{
(P) (cm | fdd | fdi) &
(P) (data-driven) &
(P) (unbalanced data | unseen classes) &
(I) (approach | model | method | process)
(I) ((machine | deep) learning)
}
```

Fig. 1: *String* de base para a busca automática.

Como última atividade da fase de Planejamento, foram definidos critérios de elegibilidade para inclusão e exclusão de artigos, conforme apresentado na Tabela I.

III. REFERENCIAL TEÓRICO E TERMINOLOGIAS

Esta seção tem por objetivo trazer as principais definições de conceitos e termos utilizados neste artigo.

TABELA I: Critérios de inclusão e exclusão, onde os tipos I e E significam **Inclusão** e **Exclusão**, respectivamente.

Tipo	Descrição
I	Estudos publicados em revistas, anais e conferências indexadas.
I	Estudos publicados a partir de 2016.
I	Estudos relatando métodos de aprendizado de máquina.
I	Estudos envolvendo a problemática de FDI.
E	Estudos não escritos na língua inglesa.
E	Estudos não enquadrados nos critérios de aceitação.
E	<i>Short Papers</i> (≤ 5 páginas).
E	Estudos redundantes de mesma autoria.
E	Estudos inacessíveis.
E	Estudos relatando aplicações com falhas previamente mapeadas.
E	Estudos não relacionados à questão de pesquisa.
E	Estudos que não propuseram método para FDI.

A. Detecção e Diagnóstico de Falhas

A **detecção de falhas** indica que algo está errado no sistema, determinando se uma falha ocorreu ou não [8], [9]. O **isolamento de falhas** determina a localização exata e a causa de uma falha [8], podendo-se determinar seu tipo [9]. A **identificação de falhas** determina a sua magnitude [8], sendo também considerada por alguns autores a especificação da severidade da falha [9]. Por fim, o **diagnóstico de falhas** é a união das etapas de isolamento e identificação de falhas.

B. Métricas

A seguir, são apresentadas as métricas mais utilizadas pelos estudos primários identificados neste artigo. Para a compreensão das métricas, os seguintes acrônimos são definidos: Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN), os quais podem ser visualizados e compreendidos através da Matriz de Confusão exemplificada na Fig. 2.

	+	-	
+	VP	FN	Observado
-	FP	VN	
	Predito		

Fig. 2: Matriz de Confusão.

Acurácia é a proporção de classificações corretas (positivas e negativas) [10]. É calculada como

$$Acurácia = \frac{VP + VN}{VP + FN + VN + FP} \quad (1)$$

Sensibilidade, também conhecido como *Recall*, é a proporção de predições corretas em relação ao total de amostras positivas [11]. É calculada como

$$Sensibilidade = \frac{VP}{VP + FN} \quad (2)$$

Precisão é a razão entre as amostras positivas classificadas corretamente e o total de amostras positivas classificadas correta ou incorretamente [11]. É calculada como

$$Precisão = \frac{VP}{VP + FP} \quad (3)$$

F1-Score, também conhecida como *F-measure*, é a proporção de previsões corretas da categoria alvo em relação a soma dos Verdadeiros Positivos [11]. É calculada como

$$F1 = \frac{2 \times \text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (4)$$

G-mean ou Média Geométrica é utilizada para conjuntos desbalanceados, considerando a classe majoritária e minoritária, quando são igualmente importantes [12]. É calculada como

$$Gmean = \sqrt{\frac{VP}{VP + FN} \times \frac{VN}{VN + FP}} \quad (5)$$

C. Aprendizado de Máquina

Este subseção sintetiza os principais conceitos de Aprendizado de Máquina (AM) pela maior recorrência nos resultados obtidos por este MSL.

1) *Tipos*: existem alguns problemas típicos de AM como: aprendizado supervisionado, não supervisionado, e por reforço. Existem ainda tipos híbridos como aprendizado semi-supervisionado, auto-supervisionado, e de várias instâncias. Por terem maior recorrência nos resultados obtidos neste MSL, serão sintetizadas apenas os tipos não supervisionado e semi-supervisionado.

No tipo **não supervisionado** inexistente o supervisor para mapear previamente entradas para rótulos de saídas. Com isto, um dos objetivos é encontrar agrupamentos de dados com base em semelhanças de suas características [13].

O tipo **semi-supervisionado** é útil para tarefas em que apenas parte dos exemplos de treinamento possuem rótulos de classe. Ou seja, utiliza passivamente dados rotulados e não rotulados [14].

2) *Técnicas*: existem diversas técnicas aplicáveis ao AM, como aprendizagem multitarefa, por conjuntos, por transferência, ativo, e *online*. Neste artigo, serão abordadas as duas últimas, por serem mais recorrentes nos resultados obtidos detalhados na Seção IV.

O **Aprendizado Ativo** é o processo de decidir quais dados serão apresentados a um especialista humano para a rotulação [15]. Faz parte desta estratégia de aprendizado a denominada *Human-in-the-Loop*.

O **Aprendizado Online**, também conhecido como Aprendizado Incremental, tem como um de seus algoritmos variações incrementais das Árvore de Decisão, como o algoritmo *Very Fast Decision Tree* (VFDT) [11]. Neste caso, inicialmente, não se recebe todo o *data set* para treinamento do modelo, sendo as instâncias para treino recebidas lentamente, fazendo com que o algoritmo se adapte com o decorrer do tempo [13]. Esta é uma técnica considerada como relevante para problemas de *Data Stream*.

IV. CONDUÇÃO E RESULTADOS DO MAPEAMENTO SISTEMÁTICO DA LITERATURA

Esta seção apresenta a condução do MSL e a síntese dos resultados obtidos. A coleta de dados nas bases bibliográficas deste MSL foi realizada em 10 de junho de 2021.

A. Seleção de Artigos

Inicialmente, após a aplicação da *string* de busca nas bases bibliográficas, foram obtidos 4.078 títulos, sendo removidos 1.536 por serem publicações anteriores ao ano de 2016. Dos 2.542 títulos remanescentes, 187 foram excluídos por serem duplicatas.

Posteriormente, foram aplicados os critérios de elegibilidade descritos na Tabela I, sendo selecionados, então, 47 títulos para revisão e extração de dados. Buscando-se selecionar os artigos de maior relevância, os 47 artigos foram agrupados em classes por ano, removendo-se os artigos que não atingiram a quantidade de citações¹ dada por $q = \frac{c}{t}$, onde c representa a quantidade de citações da classe e t a quantidade de títulos da classe.

Um total de 22 artigos foram removidos em função do número de citações. Ao final desse processo de seleção de artigos, apenas 25 artigos foram mantidos. A Fig. 3 apresenta as porcentagens dos trabalhos excluídos pelo critério de citações em função do ano de publicação.

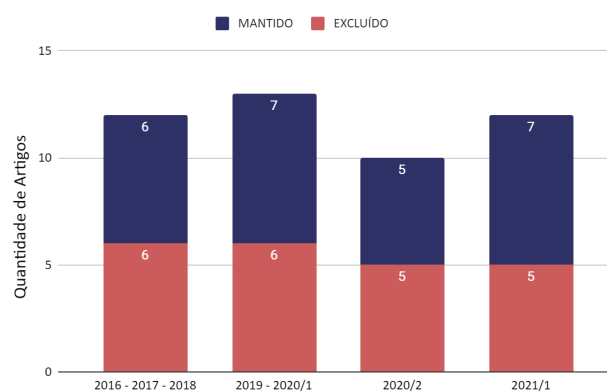


Fig. 3: Seleção de trabalhos com base na quantidade de citações.

A Fig. 4 apresenta a distribuição dos periódicos de acordo com o índice *CiteScore*. Nota-se que a distribuição se concentra nos índices *CiteScore* a partir de 94%, mostrando a relevância acadêmica e científica do conjunto de artigos obtidos. De acordo com o QUALIS/CAPES utilizado para estratificação da qualidade de publicações, o conjunto de artigos selecionados é composto por publicações com estratos A2 (*percentil* > 75%) e A1 (*percentil* > 87,5%).

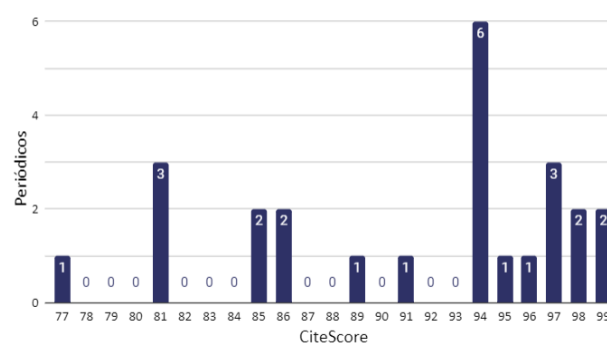


Fig. 4: Distribuição de periódicos pelo índice *CiteScore*.

¹A quantidade de citações de um artigo foi obtida por meio de informações do Google Scholar.

B. Distribuição de Publicações por Ano

Conforme mencionado na Seção I, 1.536 títulos foram publicados antes do ano de 2016 e 2.355 títulos publicados de 2016 até junho de 2021, mostrando uma tendência de alta da temática de detecção e isolamento de falhas por meio da abordagem *Data-Driven*.

A Fig. 5 apresenta a distribuição dos 25 artigos selecionados na última etapa do MSL, mostrando a tendência de alta do número de publicações nos últimos anos. Nota-se que, em 2021, apesar de ter sido considerado apenas o primeiro semestre, a quantidade de artigos de interesse já encontra-se próxima de superar o ano de 2020, confirmando a importância e a atualidade do tema.




Fig. 5: Distribuição de publicações por ano e tendência.

Tal fato se apoia na evolução das capacidades de armazenamentos de grandes conjuntos de dados, processamentos e análises, por meio da ampliação do potencial de técnicas de aprendizado de máquina.

C. Análise por Periódicos e Conferências

Os artigos selecionados foram publicados em 19 periódicos distintos e nenhum título apresentado em conferências foi obtido. Dentre os 25 estudos primários selecionados na última etapa deste MSL, 15 títulos foram publicados em periódicos da área de Computação, enquanto 10 artigos foram obtidos a partir de periódicos de outras áreas, como Engenharia Eletrônica, Engenharia Mecânica, Instrumentação, Sustentabilidade, entre outras. A Fig. 6 apresenta a distribuição dos títulos pelas categorias de Computação ou outras.

O periódico encontrado com maior quantidade de publicações foi o *Neurocomputing*, com 4 estudos primários, representando 16% dos artigos selecionados, seguido do periódico *Energy and Buildings* com 3 (12%) das publicações e *IEEE Access* com 2 (8%) dos títulos.




Fig. 6: Distribuição de títulos por categoria de periódicos.

D. Extração de Dados

Após a seleção dos estudos primários, a Tabela II foi elaborada para sintetização dos dados extraídos. Todos os 25 artigos mantidos na última etapa do MSL foram analisados, sendo sintetizados apenas 15 estudos primários, por serem considerados mais relevantes e com maior interseção com a pergunta de pesquisa descrita na Seção II.

A seguir, as colunas da Tabela II serão brevemente contextualizadas.

A coluna **Data set** contém a base de dados utilizada para realização dos experimentos, gerada pelos próprios autores ou obtida a partir de *data sets* públicos.

A coluna **FDI** indica se o autor considerou apenas a etapa de Detecção de Falha (D), Detecção e Isolamento de Falhas (DI) ou Detecção e Diagnóstico de Falhas (DD).

A coluna **Técnicas**, apresenta as técnicas de Aprendizado de Máquina utilizadas nos experimentos.

A coluna **Estratégia para Novas Classes** explana como os autores consideraram as situações em que novos modos de falha surgem durante a operação do equipamento. Em outras palavras, as estratégias utilizadas para se considerar novas classes que surgem durante a fase de teste do algoritmo.

1) **Data sets e Equipamentos**: o mais utilizado foi o Tennessee Eastman, com 3 menções cada. Ele representa um processo químico industrial com o objetivo de desenvolver, estudar e avaliar tecnologias para controle de processos [16]. Já o ASHRAE RP-1043 e o RP-1312 representam conjuntos de dados obtidos a partir de sensores de sistemas HVAC (*Heating, Ventilation and Air-Conditioning*).

Para sistemas aeronáuticos, foi utilizado o N-CMAPPS (*new Commercial Modular Aero-Propulsion System Simulation*), o AGTF30 (*Advanced Geared Turbofan*), ambos relacionados aos motores *Turbofan* [17], e o GNAT *Aircraft Data* para estruturas aeronáuticas [18].

2) **FDI**: todos os estudos primários selecionados consideraram ao menos a detecção e o isolamento de falha (DI). Apenas 2 artigos consideraram a detecção e o diagnóstico (DD), o qual também inclui a fase de Isolamento.

3) **Técnicas**: apresentaram grande diversidade, deixando claro que não existe apenas um método para o desenvolvimento de detecção e diagnóstico de falhas. Infere-se, desta forma, a existência de uma lacuna de pesquisa considerável, uma vez que nenhuma técnica específica predomina e os estudos foram publicados recentemente.

4) **Estratégias para Novas Classes**: percebe-se que vêm sendo adotadas estratégias adaptativas e incrementais para considerar novos modos de falha (classes) nos modelos preditivos iniciais, pois apenas [17] não levou em conta a expansão de modos de falhas inéditos. Além disso, apenas 4 artigos utilizaram a supervisão humana ou o aprendizado Ativo para rotular as amostras inéditas não vistas durante a fase de treinamento dos modelos.

5) **Métricas**: a maioria dos artigos apresenta a acurácia como métrica para comparação entre os resultados. As outras métricas utilizadas foram: *F1-score*, *G-mean* e sensibilidade.

6) **Contribuição**: diferentes níveis de contribuição foram propostos pelos autores. A proposição de um novo método foi encontrada em 6 artigos, a proposição de um novo *framework* em 3 artigos, a proposição de uma nova abordagem ou de um novo modelo em 2 artigos cada, e a proposição de um novo algoritmo ou uma nova metodologia em apenas 1 artigo cada.

TABELA II: Extração de dados das publicações mapeadas. Acrônimos utilizados na tabela: **AB** (Ada Boost); **AGTF** (Advanced Geared Turbofan); **AMI** (Adjusted Mutual Information); **AMIG** (Adjusted Mutual Information Gain); **C** (Completeness); **CNN** (Convolutional Neural Network); **CWRU** (Case Western Reserve University); **DH** (Dasgupta's and Hsu's cluster-adaptive); **DNN** (Deep Neural Network); **DT** (Decision Tree); **FDI** (Deteção e Isolamento); **DD** - Deteção, Isolamento e Diagnóstico; **DI** - Deteção e Isolamento); **FN** (False Negative rate); **GAN** (Generative Adversarial Network); **GMM** (Gaussian Mixture Model); **H** (Homogeneity); **HVAC** (Heating, Ventilation, Air-Conditioning); **KNN** (K-Nearest Neighbor); **KPCA** (Kernel Principal Component Analysis); **LR** (Logistic Regression); **LSG** (Linear Separability Gain); **MMI** (Mean Mutual Information); **MSVM** (Multiclass Support Vector Machine); **N-CMAPPS** (New Commercial Modular Aero-Propulsion System Simulation); **NC** (Number of Clusters); **NN** (Neural Network); **OC-SVM** (One-class Support Vector Machine); **PIR** (Performance Improvement Ratio); **PIR** (Performance Improvement Ratio); **QDA** (Quadratic Discriminant Analysis); **SAE** (Supervised Autoencoder); **SHM** (Structure Health Management); **SOM** (Self Organizing Map); **TFDK** (Tree-structured Fault Dependence Kernel); **TP** (True Positive rate); **VAE** (Variational Autoencoder).

#	Ano	Data set	Equipamento	FDI	Técnicas	Estratégia para Novas Classes	Métricas	Contribuição
[18]	2018	Gnat Aircraft Data	Estrutura Aeronáutica (SHM)	DI	DH Active Learning	Cria agrupamentos dinamicamente, por meio de diagnóstico probabilístico	Acurácia	Algoritmo
[12]	2018	CWRU	Rolamento	DI	KNN, reverse-KNN	Incremental	Acurácia, G-mean	Modelo
[17]	2020	N-CMAPSS e AGTF30	Motores Turbofan	DI	VAE	Não prevê a evolução dos modos de falha	Acurácia, TP, FN, NC, H, C, AMI, AMIG, LSG e MMI	Método
[19]	2016	ASHRAE RP-1043	HVAC	DD	MSVM, DT, NN, AB, QDA, LR	Rotulação Humana, Aprendizado Online e Incremental	Acurácia e Custo	Framework e Método TFDK
[20]	2021	ASHRAE RP-1043	HVAC	DI	GAN	Autotreinamento iterativo	Acurácia	Método
[21]	2021	ASHRAE RP-1312	HVAC	DI	NN + SAE	Retreinamento	Precisão, Sensibilidade e F1 Score	Modelo
[22]	2021	ASHRAE RP-1312	HVAC	DI	NN Semissupervisionado com self-training	Adaptativo	PIR	Abordagem
[23]	2018	Tennessee Eastman	Industrial	DI	DNN	Aprendizado Incremental e Aprendizado Ativo	G-mean e Sensibilidade	Método IMDNN
[24]	2020	Tennessee Eastman	Industrial	DI	Incremental One-class e Dynamic Shallow NN	Retreinamento em lote		
[25]	2016	Próprio	Sistema de Direção Automotivo	DI	OC-SVM e Multi-layer NN	Identifica apenas uma classe nova	Acurácia e Performance de Treinamento	Metodologia
[26]	2020	Próprio	Motor Elétrico	DI	SOM incremental + online	Supervisão humana + adaptação do modelo	Acurácia	Método
[27]	2020	Próprio	Trem de Força	DD	SVM + CNN	Incremental	Acurácia	Método
[28]	2021	Próprio	Sistema de Parafusamento Automotivo	DI	GMM + Regra de bayes	Supervisão Humana periódica + incremental	-	Abordagem
[29]	2020	PRONTO	Industrial	DI	GMM + KPCA	Adaptativo	-	Framework
[30]	2017	Simulador de Falhas Industrial e Medidor de Descarga Parcial de Equipamentos Eletrônicos	Máquina Rotativa	DI	GMM	Agrupamento adaptativo	Acurácia	Framework

V. CONCLUSÃO

O presente artigo relata a execução e os resultados de um Mapeamento Sistemático da Literatura (MSL), cobrindo os principais estudos primários relativos à detecção e isolamento de falhas (*Fault Detection and Isolation* - FDI), utilizando a abordagem *Data-Driven* e com a possibilidade de reconhecimento de novos modos de falha após o treinamento inicial do modelo de Aprendizado de Máquina (AM). Com isto, foi possível se compreender, de maneira abrangente, as limitações e perspectivas desta proeminente área de pesquisa.

Dentre os 4.078 títulos recuperados inicialmente, foram selecionados apenas os 15 artigos considerados como mais relevantes publicados a partir de 2016 e com estrato QUALIS/CAPES superior ou igual a classificação A2. Verificou-se que não há consenso na literatura a respeito da utilização de uma técnica específica de AM para problemas de FDI em sistemas complexos, usando a abordagem *Data-Driven*.

Para a consideração de novos modos de falha, a maioria dos artigos propôs a utilização de aprendizado *Online*. Alguns autores propuseram métodos para integrar diferentes tipos de AM, como o aprendizado *Online*, Ativo, Não Supervisionado e Semi-supervisionado.

Como direcionamento para estudos futuros, partindo dos resultados deste MSL, torna-se possível inferir que a FDI em sistemas complexos permanece um campo aberto com amplas possibilidades para exploração, necessitando de novas pesquisas para que os métodos propostos possam ser dinâmicos o suficiente para considerarem novos modos de falha e novas condições operacionais e ambientais em seus modelos de AM.

AGRADECIMENTOS

Os autores deste artigo agradecem ao Comando da Aeronáutica (COMAER), ao Instituto Tecnológico de Aeronáutica (ITA), ao Programa de Pós-Graduação em Aplicações Operacionais (PPGAO), e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, *grant* 423023/2018-7) pelo suporte e infraestrutura oferecidos durante todo o desenvolvimento deste trabalho de pesquisa.

REFERÊNCIAS

- [1] A. J. Guillén, A. Crespo, M. Macchi, and J. Gómez, "On the role of Prognostics and Health Management in advanced maintenance systems," *Production Planning and Control*, vol. 27, no. 12, pp. 991–1004, 2016.
- [2] R. Kothamasu, S. H. Huang, and W. H. VerDuin, "System health monitoring and prognostics—a review of current paradigms and practices," *The International Journal of Advanced Manufacturing Technology*, vol. 28, no. 9–10, pp. 1012–1024, 2006.
- [3] Z. Sadough Vanini, K. Khorasani, and N. Meskin, "Fault detection and isolation of a dual spool gas turbine engine using dynamic neural networks and multiple model approach," *Information Sciences*, vol. 259, pp. 234–251, 2014. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0020025513004131>
- [4] A. Valdes and K. Khorasani, "Dynamic neural network-based pulsed plasma thruster (ppt) fault detection and isolation for the attitude control system of a satellite," in *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*. IEEE, June 2008, pp. 2689–2695.
- [5] M. K. Michael G. Pecht, *Prognostics and Health Management of Electronics: Fundamentals, Machine Learning, and the Internet of Things*, 2nd ed. Hoboken, NJ: Wiley, 2018.
- [6] T. Pohl, "Why big data can help to keep planes in the air," 2015. [Online]. Available: <https://blogs.sap.com/2015/01/20/why-airlines-need-to-keep-planes-in-the-air/>
- [7] E. Nakagawa, K. Scannavino, S. Fabbri, and F. Ferrari, *Revisão Sistemática da Literatura em Engenharia de Software: Teoria e Prática*, 1st ed. Rio de Janeiro: Elsevier Brasil, 2017.
- [8] J. Gertler, *Fault Detection and Diagnosis in Engineering Systems*, ser. Electrical Engineering and Ele. Taylor & Francis, 1998. [Online]. Available: <https://books.google.com.br/books?id=fmPyTbbqKfIC>
- [9] H. Chen, P. TIÑO, and X. Yao, "Cognitive fault diagnosis in tennessee eastman process using learning in the model space," *Computers and Chemical Engineering*, vol. 67, pp. 33–42, 8 2014.
- [10] C. Santos, "Avaliação do uso de classificadores para verificação de atendimento a critérios de seleção em programas sociais," Master's thesis, Dissertação (Programa de Pós Graduação em Modelagem computacional), 2017.
- [11] J. Gama, "Knowledge Discovery from Data Streams," *Knowledge Discovery from Data Streams*, pp. 21–26, 2020.
- [12] J. Liu, Y. An, R. Dou, H. Ji, and Y. Liu, "Helical fault diagnosis model based on data-driven incremental merge," *Computers & Industrial Engineering*, vol. 125, pp. 517–532, 2018.
- [13] E. Alpaydin, *Introduction to machine learning*. MIT press, 2020.
- [14] A. C. Lorena, J. Gama, and K. Faceli, *Inteligência Artificial: Uma abordagem de aprendizado de máquina*, 3rd ed. Grupo Gen-LTC, 2021.
- [15] R. Monarch, *Human-in-the-Loop Machine Learning: Active learning and annotation for human-centered AI*. Manning Publications, 2021.
- [16] J. J. Downs and E. F. Vogel, "A plant-wide industrial process control problem," *Computers & chemical engineering*, vol. 17, no. 3, pp. 245–255, 1993.
- [17] M. Arias Chao, B. T. Adey, and O. Fink, "Implicit supervision for fault detection and segmentation of emerging fault types with Deep Variational Autoencoders," *Neurocomputing*, vol. 454, pp. 324–338, 2021. [Online]. Available: <https://doi.org/10.1016/j.neucom.2021.04.122>
- [18] L. Bull, K. Worden, G. Manson, and N. Dervilis, "Active learning for semi-supervised structural health monitoring," *Journal of Sound and Vibration*, vol. 437, pp. 373–388, 2018.
- [19] D. Li, Y. Zhou, G. Hu, and C. J. Spanos, "Fault detection and diagnosis for building cooling system with a tree-structured learning method," *Energy and Buildings*, vol. 127, pp. 540–551, 2016.
- [20] B. Li, F. Cheng, H. Cai, X. Zhang, and W. Cai, "A semi-supervised approach to fault detection and diagnosis for building HVAC systems based on the modified generative adversarial network," *Energy and Buildings*, vol. 246, p. 111044, 2021. [Online]. Available: <https://doi.org/10.1016/j.enbuild.2021.111044>
- [21] W. S. Yun, W. H. Hong, and H. Seo, "A data-driven fault detection and diagnosis scheme for air handling units in building HVAC systems considering undefined states," *Journal of Building Engineering*, vol. 35, no. July 2020, p. 102111, 2021. [Online]. Available: <https://doi.org/10.1016/j.jobee.2020.102111>
- [22] C. Fan, X. Liu, P. Xue, and J. Wang, "Statistical characterization of semi-supervised neural networks for fault detection and diagnosis of air handling units," *Energy and Buildings*, vol. 234, p. 110733, 2021. [Online]. Available: <https://doi.org/10.1016/j.enbuild.2021.110733>
- [23] Z. Hu and P. Jiang, "An Imbalance Modified Deep Neural Network with Dynamical Incremental Learning for Chemical Fault Diagnosis," *IEEE Transactions on Industrial Electronics*, vol. 66, no. 1, pp. 540–550, 2018.
- [24] R. Arunthavanathan, F. Khan, S. Ahmed, S. Intiaz, and R. Rusli, "Fault detection and diagnosis in process system using artificial intelligence-based cognitive technique," *Computers and Chemical Engineering*, vol. 134, p. 106697, 3 2020.
- [25] J. A. Carino, M. Delgado-Prieto, D. Zurita, M. Millan, J. A. Ortega Redondo, and R. Romero-Troncoso, "Enhanced Industrial Machinery Condition Monitoring Methodology Based on Novelty Detection and Multi-Modal Analysis," *IEEE Access*, vol. 4, pp. 7594–7604, 2016.
- [26] J. J. Saucedo-Dorantes, M. Delgado-Prieto, R. A. Osornio-Rios, and R. D. J. Romero-Troncoso, "Industrial Data-Driven Monitoring Based on Incremental Learning Applied to the Detection of Novel Faults," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 9, pp. 5985–5995, 2020.
- [27] J. S. L. Senanayaka, H. Van Khang, and K. G. Robbersmyr, "Toward self-supervised feature learning for online diagnosis of multiple faults in electric powertrains," *IEEE Transactions on Industrial Informatics*, vol. 17, no. 6, pp. 3772–3781, 2020.
- [28] M. Ferhat, M. Ritou, P. Leray, and N. Le Du, "Incremental discovery of new defects: application to screwing process monitoring," *CIRP Annals*, vol. 00, pp. 16–19, 2021. [Online]. Available: <https://doi.org/10.1016/j.cirp.2021.04.026>
- [29] R. Tan, T. Cong, J. R. Ottewill, J. Baranowski, and N. F. Thornhill, "An on-line framework for monitoring nonlinear processes with multiple operating modes," *Journal of Process Control*, vol. 89, pp. 119–130, 2020.
- [30] H. C. Yan, J. H. Zhou, and C. K. Pang, "Gaussian Mixture Model Using Semisupervised Learning for Probabilistic Fault Diagnosis Under New Data Categories," *IEEE Transactions on Instrumentation and Measurement*, vol. 66, no. 4, pp. 723–733, 2017.