



GRUPO DE ESTUDO DE GERAÇÃO HIDRÁULICA - GGH

DETECÇÃO E DIAGNÓSTICO DE FALHAS EM HIDROGERADORES BASEADOS EM MÉTODOS NÃO SUPERVISIONADOS DE INTELIGÊNCIA ARTIFICIAL

MIGUEL ANGELO DE CARVALHO MICHALSKI (1); ARTHUR HENRIQUE DE ANDRADE MELANI (1); RENAN FAVARÃO DA SILVA (1); GILBERTO FRANCISCO MARTHA DE SOUZA (1)
UNIVERSIDADE DE SÃO PAULO (1)

RESUMO

Estratégias como a Manutenção Baseada na Condição se destacam por permitirem que os estados de ativos físicos sejam monitorados e intervenções sejam realizadas no momento mais adequado. Contudo, tais abordagens dependem do sucesso de métodos de Detecção e Diagnóstico de Falhas (DDF) mesmo quando dados de falhas previamente rotulados não estão disponíveis. Neste contexto, este artigo propõe uma estrutura (*framework*) que visa automatizar a DDF baseada em técnicas de aprendizado de máquinas não supervisionadas e no conhecimento de especialistas. A estrutura proposta foi implementada para um modelo simplificado de hidrogerador e os resultados demonstram que o método além de viável, é robusto, podendo ser utilizado futuramente em casos reais.

PALAVRAS-CHAVE: Manutenção Baseada na Condição, Detecção e Diagnóstico de Falhas, Aprendizado de máquinas não supervisionado, Análise de Componentes Principais, Redes Bayesianas.

1.0 INTRODUÇÃO

No atual cenário econômico, a produtividade pode ser considerada como uma das poucas garantias de sobrevivência das organizações. Diante do atual nível de globalização e competitividade, uma boa estratégia de manutenção é obrigatória para cumprir tal meta, aumentando a disponibilidade dos equipamentos [1]. Além disso, a manutenção representa um grande percentual das despesas operacionais de uma organização, sendo uma área que não está isenta de grandes desafios [2].

Ativos físicos, tais como instalações e equipamentos, por mais bem projetados que sejam, não permanecem seguros ou confiáveis se não houver uma manutenção contínua [3]. Uma vez que falhas inesperadas podem trazer efeitos adversos tanto para a operação de uma organização, quanto ao meio ambiente, podendo inclusive resultar em acidentes graves, o principal desafio para as equipes de manutenção é implementar uma estratégia que maximize a disponibilidade e a eficiência dos ativos ao mesmo tempo que controle a taxa de deterioração dos equipamentos envolvidos. Consequentemente, pode-se garantir uma operação segura, ecologicamente correta e cujos custos possam ser minimizados [4]. Desta forma, estratégias de gerenciamento da manutenção são essenciais para garantir o aumento da eficiência, disponibilidade e qualidade de uma organização [5].

A manutenção preditiva é uma abordagem de manutenção com estratégias integradas baseada no risco e na confiabilidade, sendo atualmente bastante difundida devido às tecnologias disponíveis para monitorar o desempenho dos equipamentos. Esta abordagem de manutenção usa o monitoramento das condições dos sistemas como uma estratégia que permite entender o estado dos ativos físicos e planejar as atividades de manutenção antes da ocorrência de uma falha [6]. Em outras palavras, o equipamento passa por intervenções de manutenção apenas quando há evidência direta de que sua deterioração ocorreu [1]. Essa estratégia, que recomenda ações de manutenção com base nas informações da integridade do maquinário coletadas por meio do monitoramento contínuo, é definida como Manutenção Baseada nas Condições (MBC), sendo um dos principais componentes da manutenção preditiva [7].

A Detecção e Diagnóstico de Falhas (DDF) é um processo de grande importância em uma estratégia de MBC. Basicamente, a detecção de falha pode ser definida como o processo de reconhecer que uma falha está ocorrendo no sistema, enquanto o diagnóstico de falha é aplicado para encontrar a causa e a localização da falha. Métodos avançados de detecção de falhas são baseados tanto em modelos matemáticos de sinais e processos, quanto na teoria de sistemas e métodos de modelagem de processos para identificar o desenvolvimento de sintomas de uma falha. Os métodos de diagnóstico de falhas, por outro lado,

são baseados em relações causais de sintomas aplicando-se métodos de decisão estatística, inteligência artificial e análise de dados. Consequentemente, a DDF pode ser um campo desafiador que compreende a teoria de sistemas físicos, experimentos e cálculos computacionais [8], especialmente quando se trata de sistemas complexos em setores estratégicos, como geração de energia, infraestrutura e indústrias petroquímicas.

De fato, a DDF é uma área de pesquisa ativa que tem incentivado o desenvolvimento de uma ampla gama de métodos e heurísticas [9]. Muitos autores abordam métodos de DDF em seus artigos, apresentando revisões e estudos comparativos em várias áreas de aplicação e, considerando esses estudos e os atributos dos métodos, a DDF pode ser classificada em algumas categorias principais, como abordagens baseadas em modelos e abordagens baseadas em dados, técnicas quantitativas e qualitativas (também conhecidas como métodos baseados em conhecimento) e métodos supervisionados ou não supervisionados [10]. Cada uma dessas famílias de métodos tem seus pontos fortes e fracos, sendo uma tarefa difícil definir qual método é o mais adequado para uma determinada aplicação. Objetivamente, pode-se definir alguns requisitos para apoiar tal decisão [11–13], mas ainda assim pode-se concluir que nenhum método de DDF possui isoladamente todas as características desejáveis que um método completo deve possuir, impulsionando futuros desenvolvimentos que apontem para soluções híbridas, nas quais dois ou mais métodos se integrem, complementando-se e superando suas limitações.

No entanto, deve-se notar que, diante dos desafios recentemente impostos pela indústria 4.0, métodos estatísticos multivariados baseados em dados têm recebido mais atenção do que outros métodos [16]. Em muitas aplicações atuais, ter acesso a dados previamente rotulados relacionados a condições do sistema em falha é geralmente raro, caro e difícil. Nestes casos, geralmente apenas dados do sistema em condições saudáveis e sob certas condições operacionais estão disponíveis [10]. Portanto, técnicas como Análise de Componentes Principais (do inglês, *Principal Component Analysis*, PCA) e Mínimos Quadrados Parciais (do inglês, *Partial Least Squares*, PLS) já foram bem estabelecidas e outras técnicas, como Análise de Componentes Independentes (do inglês, *Independent Component Analysis*, ICA) e Redes Bayesianas (do inglês, *Bayesian Networks*, BN), começam a ser largamente utilizadas. Diversas combinações híbridas de técnicas de DDF baseadas em dados podem ser encontradas na literatura, mas a combinação PCA-BN é a que mais vem se destacando na última década [14].

A aplicação do método híbrido PCA-BN se demonstra muito promissora pois, se por um lado a PCA permite a detecção rápida de variações em sistemas com grande quantidade de dados monitorados, por outro lado a BN tem sido usada com sucesso ao estabelecer uma relação de causa e efeito, permitindo a resolução de problemas de previsão e diagnóstico [16]. No entanto, uma limitação da PCA como método de DDF é a necessidade de um modelo invariante no tempo construído a partir dos dados de entrada. Isso torna o método PCA tradicional ineficaz na detecção de falhas incipientes em sistemas dinâmicos, especialmente quando a relação sinal-ruído é desfavorável [9,17]. Nesse caso, uma variação adaptativa da PCA, como a Análise do Componente Principal de Janela Móvel (do inglês, *Moving Window Principal Component Analysis*, MWPCA), pode ser uma alternativa interessante para contornar esse problema.

Neste contexto, este trabalho propõe uma estrutura (*framework*) híbrida para automatizar o processo de DDF baseado nos algoritmos da MWPCA e da BN. Esta nova abordagem permite que grandes redes de conhecimento provenientes de especialistas sejam traduzidas em entradas estruturadas para o processo de DDF, evitando a perda de informações. Em outras palavras, a estrutura proposta integra o conhecimento disponível sobre o sistema analisado para construir automaticamente a estrutura do processo de DDF baseado na MWPCA e na BN, agilizando a implementação e tornando a aplicação mais robusta. Esta abordagem é validada através de um estudo de caso considerando dados simulados de um modelo simplificado de um hidrogenador, demonstrando a aplicabilidade da estrutura em sistemas complexos de engenharia.

O restante deste artigo é organizado da seguinte forma: na seção 2 é apresentada uma revisão bibliográfica com o contexto do método apresentado, que por sua vez é abordada na seção 3. Na sequência, um estudo de caso que exemplifica a aplicação do método é apresentado na seção 4. Por fim, na seção 5, apresentam-se as conclusões deste trabalho.

2.0 REVISÃO BIBLIOGRÁFICA

Conforme apresentado anteriormente, processos de DDF são importantes na estratégia MBC, influenciando diretamente o planejamento da manutenção e as tomadas de decisão. Nesse contexto, o monitoramento dos ativos físicos se torna um fator chave para o sucesso das atividades de manutenção. Porém, quando se trata de sistemas complexos, muitas variáveis são monitoradas simultaneamente e a aplicação de uma técnica que reduza a dimensionalidade do problema e permita uma análise conjunta dos dados pode ser aplicada [16]. Neste processo, o conjunto inicial de dados é reduzido a *clusters* (agrupamentos de dados) mais gerenciáveis para seu processamento [13]. Uma técnica de extração de características estatísticas amplamente usada para monitoramento de processos é a PCA, sendo uma das abordagens baseadas em dados mais antigas, populares e bem estabelecidas usadas nas últimas duas ou três décadas na detecção de falhas em processos industriais [16,18].

No entanto, uma vez que a PCA e suas variações não são capazes de determinar uma relação de causa e efeito que correlacione os sintomas observados através das variáveis monitoradas aos possíveis modos de falha em andamento no sistema analisado, um método de diagnóstico deve ser usado. Desta forma, devido à flexibilidade de ser modelada a partir do processo de conhecimento e dados históricos, a BN torna-se extremamente atraente para diversas aplicações. Portanto, em uma proposta híbrida considerando a PCA e a BN para um processo de DDF, o primeiro método torna-se responsável pela detecção da falha e o segundo pelo seu diagnóstico. Além disso, a partir da estrutura da BN é possível verificar graficamente as correlações entre as características extraídas pela PCA e os modos de falha detectados. Esta combinação híbrida, embora recente, tem sido explorada por diversos autores nos últimos anos, com a maioria das aplicações relacionadas a processos químicos.

Apesar dos exemplos de combinação PCA-BN encontrados na literatura [16,19–24], é interessante notar que uma abordagem de métodos híbridos envolvendo uma variação adaptativa de PCA e BN não é facilmente encontrada na literatura. Nesse contexto, a estrutura proposta neste trabalho traz uma inovação ao combinar a MWPCA e a BN, permitindo ao método realizar a detecção de falhas em sistemas dinâmicos, superando um problema característico do PCA em relação aos conjuntos de dados dependentes do tempo, e tornando a proposta deste trabalho ainda mais relevante. Além disso, o método proposto usa o conhecimento especializado para apoiar os algoritmos de aprendizado de máquina a partir de um método de coleta particularmente desenvolvido para essa aplicação, aproximando e integrando o conhecimento prático do dia a dia de plantas industriais às técnicas de inteligência artificial utilizadas.

3.0 ESTRUTURA PROPOSTA

Conforme mencionado anteriormente, este artigo propõe uma estrutura (*framework*) híbrida para automatizar o processo de DDF baseado nos métodos MWPCA e BN. Esta abordagem pode ser encontrada de forma mais detalhada em Melani *et al.* [10]. Tal estrutura possui três processos principais: (1) Realização do estudo do sistema, (2) Realização da detecção de falhas no sistema e (3) Realização do diagnóstico das falhas previamente detectadas, conforme detalhado na Figura 1.

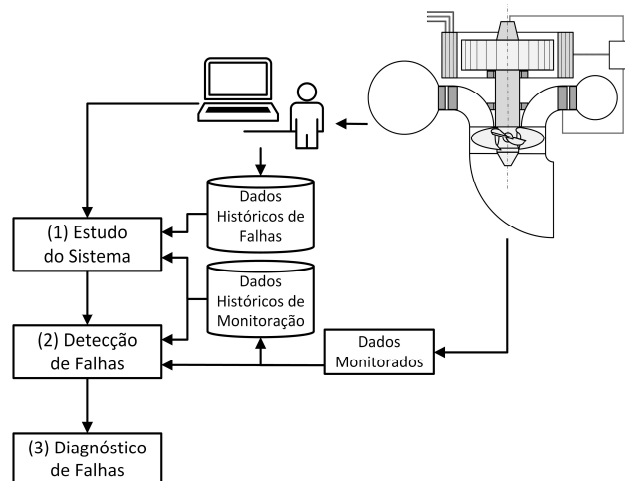


Figura 1 – Processos e entradas da estrutura proposta

O primeiro processo da estrutura, o estudo do sistema, é composto por quatro etapas que buscam coletar as informações necessárias para subsidiar os processos seguintes de detecção e diagnose das falhas. Tais etapas dependem do conhecimento de especialistas e consistem na definição dos componentes do sistema que serão analisados, na identificação dos modos de falha de cada componente selecionado, na correlação entre os modos de falha e variáveis monitoradas que possam indicar possíveis sintomas das falhas e, por fim, na coleta dos dados relativos à taxa de ocorrência de cada modo de falha considerado. Na Tabela 1 são apresentadas as informações coletadas no processo de estudo do sistema, incluindo a definição dos *clusters* que são utilizados no processo seguinte do método de DDF proposto.

Tabela 1. Padrão da tabela de informações coletadas sobre o sistema

Componente	Modos de Falha Potenciais	Taxa de Falha (h^{-1})	Variáveis monitoradas	Cluster [Janela de observação (h)]
Componente 1	Modo de Falha A	λ_A	Variável 1	Cluster #1 [180]
			Variável 2	
	Modo de Falha B	λ_B	Variável 1	Cluster #2 [360]

		Variável 3		[480]
Componente 2	Modo de Falha C	λ_c	Variável 3	Cluster #3 [24]

Após a conclusão do estudo do sistema, é possível iniciar o processo de detecção de falhas. Este processo é composto por quatro etapas projetadas para serem executadas automaticamente a partir de um sistema informatizado [10]. Essas tarefas são a definição dos *clusters* (conjunto de variáveis que possam indicar os sintomas de um ou mais modos de falha), a construção das matrizes de entrada do algoritmo de detecção, a execução do algoritmo da PCA e a categorização dos resultados obtidos. Neste último caso, a resposta de cada *cluster* pode ser verdadeira (*true*, T), quando alguma variação no padrão dos dados é detectada, ou falsa (*false*, F), quando ocorre o oposto e nenhuma anomalia é detectada.

O processo de execução do diagnóstico das falhas é composto, por sua vez, por quatro etapas principais, começando com a construção do gráfico da BN com base nas informações sobre o sistema adquiridas no primeiro processo da estrutura. Na Figura 2 é apresentado um exemplo gráfico de uma BN construída a partir da Tabela 1. Note que as ligações entre os nós da BN são realizadas em função das variáveis monitoradas. Ou seja, cada modo de falha é conectado aos clusters que contenham pelo menos uma das variáveis monitoradas que indiquem sintomas do modo de falha em questão.




Figura 2 – Gráfico de uma rede Bayesiana

Em seguida, as Tabelas de Probabilidade Condicional (do inglês, *Conditional Probability Table*, CPT) relativas a cada nó da rede Bayesiana devem ser preenchidas. Para os nós relativos aos modos de falha, cada CPT é preenchida com o valor de confiabilidade ($R(t)$), para o caso de o modo de falha não estar ocorrendo, e probabilidade de falha ($1 - R(t)$), para o caso de o modo de falha estar ocorrendo. Para os nós relativos aos clusters, no entanto, cada CPT será preenchida considerando-se a probabilidade dos modos de falha relacionados ao cluster em questão serem detectados a partir dos sintomas presentes no mesmo. Tal probabilidade pode ser definida a priori ou ser obtida a partir da Taxa de Falsos Alarmes (do inglês, *False Alarm Rate*, FAR) e da Taxa de Detecção de Falhas (do inglês, *Fault Detection Rate*, FDR), que são dois parâmetros convencionalmente usados para avaliar o desempenho dos métodos de detecção de falhas [10]. Com as CPTs preenchidas, a inferência da BN pode ser realizada calculando a probabilidade a posteriori de cada modo de falha ser verdadeiro ou falso usando como entrada os estados dos clusters analisados. Finalmente, o processo de classificação dos modos de falhas mais prováveis de ocorrer é definido com base na probabilidade a posteriori obtida.

4.0 ESTUDO DE CASO

Neste trabalho, a abordagem proposta para DDF é aplicada a um modelo simplificado de hidrogerador, baseado em uma unidade Kaplan real de 50 MW de uma Usina Hidrelétrica (UHE) brasileira. Maiores detalhes sobre o modelo considerado e o estudo de caso podem ser encontrados em Melani *et al.* [10]. Ao todo, 30 componentes de três diferentes subsistemas (1.2. Turbina, 1.6. Gerador e 1.9. Sistema de monitoração) foram considerados no estudo de caso. A **Erro! Fonte de referência não encontrada.** apresenta uma representação simplificada da unidade geradora com a localização dos componentes considerados, incluindo os sensores.

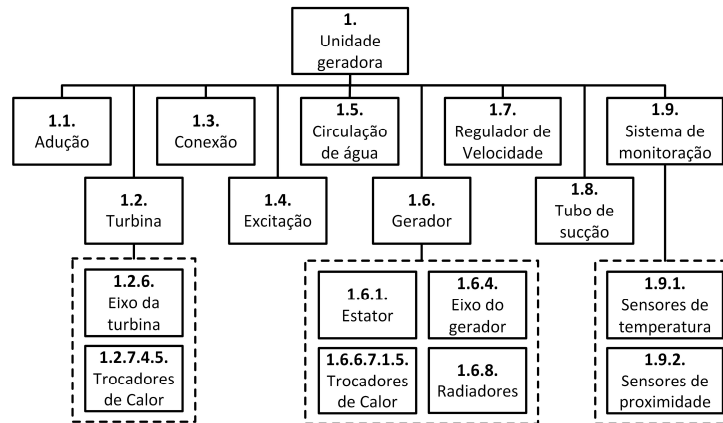


Figura 3 – Árvore funcional do sistema analisado

Dos 30 componentes, 2 pertencem à turbina (1.2.6. Eixo da turbina e 1.2.7.4.5. Trocadores de calor do sistema de resfriamento do óleo do mancal guia), 4 pertencem ao gerador (1.6.1. Estator, 1.6.4. Eixo do gerador, 1.6.6.7.1.5. Trocadores de calor do sistema de resfriamento do óleo do mancal combinado e 1.6.8. Radiadores), e 24 são sensores compreendidos em dois subsistemas do sistema de monitoração (1.9.1. e 1.9.2.). Dentre esses últimos, 20 são sensores de temperatura, sendo 4 sensores de temperatura do enrolamento do estator (1.9.1.1. a 1.9.1.4.), 4 sensores de temperatura do núcleo do estator (1.9.1.5. a 1.9.1.8.), um sensor de temperatura do ar quente do gerador (1.9.1.9), um sensor de temperatura do ar frio do gerador (1.9.1.10), um sensor de temperatura da água de saída dos radiadores (1.9.1.11), um sensor de temperatura da água de entrada dos radiadores (1.9.1.12), um sensor de temperatura do óleo no mancal combinado (1.9.1.13.), um sensor de temperatura da água de saída do trocador de calor do mancal combinado (1.9.1.14.), um sensor de temperatura do óleo no mancal guia (1.9.1.15.), um sensor de temperatura da água de saída do trocador de calor do mancal guia (1.9.1.16.), um sensor de temperatura do óleo de saída do trocador de calor do mancal combinado (1.9.1.17.), um sensor de temperatura do óleo de entrada do trocador de calor do mancal guia (1.9.1.18.) e um sensor de temperatura do óleo de entrada do trocador de calor do mancal guia (1.9.1.20.). Por outro lado, os 4 sensores de proximidade são os sensores de proximidade 0° e 90° do mancal combinado (1.9.2.1. e 1.9.2.2.) e os sensores de proximidade 0° e 90° do mancal guia (1.9.2.3. e 1.9.2.4.). A Figura 4 apresenta uma representação simplificada da unidade geradora com a localização dos componentes considerados, incluindo os sensores.




Figura 4 – Representação simplificada da unidade geradora

Os dados dos 20 sensores de temperatura são tratados como dados de processo, e desta forma são considerados os valores absolutos das temperaturas. Por sua vez, no caso dos dados dos sensores de proximidade, o valor RMS é considerado nas análises. As simulações são feitas considerando-se que os dados seriam coletados a cada 4 horas.

Ao todo são construídos 37 *clusters* a partir das 24 variáveis monitoradas. Neste estudo de caso é considerada uma relação biunívoca entre os *clusters* e os modos de falha. Dentre os 37 modos de falha considerados, 13 são de origem mecânica: vibração excessiva do eixo da turbina, vazão baixa da água de refrigeração do trocador de calor do mancal guia, vazamento de água no trocador de calor do mancal guia, vazão baixa de óleo no trocador de calor do mancal guia, vazamento de óleo no trocador de calor do mancal guia, degradação prematura do isolamento do enrolamento do estator, vibração excessiva do eixo do gerador, vazão baixa da água de refrigeração do trocador de calor do mancal combinado, vazamento de água no trocador de calor do mancal combinado, vazão baixa de óleo no trocador de calor do mancal combinado, vazamento de óleo no trocador de calor do mancal combinado, vazão baixa de água no radiador e vazamento de água no radiador. Os demais 24 modos de falha se referem a falhas de leitura de cada um dos 24 sensores, nos quais o valor lido por cada sensor não condiz com o valor real da grandeza monitorada. As falhas de origem mecânica são do tipo multiplicativa, gerando uma tendência crescente exponencial nos valores das variáveis monitoradas afetadas pela falha, enquanto que as falhas de leitura dos sensores são do tipo aditivas, gerando picos aleatórios nos sinais monitorados, como ocorreria no caso de um mal contato na cadeia de medição, por exemplo.

Os 37 *clusters* e 37 modos de falha constituem os nós da BN criada no estudo de caso. Dentre os modos de falha considerados para a construção da BN, três foram simulados e analisados de forma independente: "Vibração excessiva do eixo do gerador", "Degradação prematura do isolamento do estator a 0°" e "Falha na leitura do sensor de temperatura da água de saída do trocador de calor do mancal combinado". Os *clusters* associados aos modos de falha simulados são:

- Vibração excessiva do eixo do gerador: *cluster* #7, *cluster* #10, *cluster* #11, *cluster* #26, *cluster* #31, *cluster* #34, *cluster* #35;
- Degradação prematura do isolamento do estator a 0°: *cluster* #6, *cluster* #14, *cluster* #15, *cluster* #16, *cluster* #17, *cluster* #18, *cluster* #19, *cluster* #20 e *cluster* #21;
- Falha na leitura do sensor de temperatura da água de saída do trocador de calor do mancal combinado: *cluster* #8, *cluster* #9, *cluster* #11 e *cluster* #27.

Para cada caso foram simuladas 1.000 horas de operação, sendo que nas primeiras 350 horas o sistema permaneceu em uma condição saudável. Ou seja, na hora 350 a falha foi introduzida no sistema e as 650 horas seguintes o sistema operou em falha. Nas Figuras Figura 5, Figura 6 e Figura 7 são apresentados os resultados das 650 horas simuladas para o processo de detecção (considerando apenas os *clusters* que em algum momento durante o período considerado apresentaram um resultado positivo) e diagnose (apresentando apenas os modos de falha, com o sistema em falha para os três modos de falha analisados).




Figura 5 – Resultados da detecção e diagnóstico: vibração excessiva do eixo do gerador




Figura 6 – Resultados da detecção e diagnóstico: degradação prematura do isolamento do estator a 0°




Figura 7 – Resultados da detecção e diagnóstico: falha na leitura do sensor de temperatura da água de saída do trocador de calor do mancal combinado

Como pode ser notado, no caso da falha "vibração excessiva do eixo do gerador", na sua fase mais incipiente (aproximadamente até a 320ª hora simulada), seu diagnóstico não ocorreu de forma constante, além de uma série de falsos diagnósticos terem ocorrido. Isto se dá principalmente em função da sensibilidade do processo de detecção e pelo fato do processo de diagnóstico se basear em sintomas que, algumas vezes, podem ser interpretados como falhas em função de flutuações esporádicas nos dados monitorados, tais como ruídos ou variações inesperadas na condição de operação do sistema. Contudo, à medida que a falha analisada se torna mais evidente, mantenho uma condição de diagnóstico constante, o número de falsos diagnósticos relativos a outros modos de falha que não estão de fato ocorrendo tende a diminuir. Em outras palavras, a integração ao longo do tempo do resultado apresentado para a probabilidade a posteriori pode ser usada como evidência para confirmar o modo de falha presente no sistema.

No segundo caso simulado, o processo de detecção identificou a variação de apenas um cluster ao longo das 650 horas analisadas. Embora este cluster esteja relacionado a vários modos de falha, o processo de diagnóstico foi capaz de identificar corretamente a falha "degradação prematura do isolamento do estator a 0°" como sendo a mais evidente. No entanto, é importante notar que, neste exemplo, a variação da probabilidade a posteriori do modo de falha é mais significativa para se determinar qual a falha é a mais provável do que o próprio valor desta probabilidade. Isso porque o modo de falha analisado gera uma degradação do sistema muito lenta, o que fica evidente ao se verificar que a detecção ocorre apenas 400 horas após a introdução da falha no sistema. Na verdade, com apenas alguns sensores de temperatura ao longo da circunferência do estator, de fato, a detecção precisa desse modo de falha não é simples. Espera-se que, à medida que o modo de falha progride, outros clusters também apresentem alguma variação, indicando a detecção da falha e reforçando sua identificação.

No terceiro caso, na simulação do modo de falha "falha na leitura do sensor de temperatura da água de saída do trocador de calor do mancal combinado", em virtude da forma como os dados monitorados são afetados pela falha, esta torna-se evidente no processo de detecção. Como pode-se notar, os clusters #8 e #9, associados a este modo de falha, apresentaram uma resposta praticamente imediata à introdução da falha, o que leva ao diagnóstico da falha com uma probabilidade a posteriori em torno de 20%. No entanto, quando ocorrem variações no cluster #27, também associado à falha, a probabilidade a posteriori da falha aumenta, chegando próximo ao valor de 70% e tornando o modo de falha em questão o mais provável. Simultaneamente, quanto tal evento ocorre, outros modos de falha associados a falhas mecânicas no trocador de calor do mancal combinado tornam-se menos evidentes, demonstrando como a evidência do processo de detecção influencia os resultados do processo de diagnóstico.

5.0 CONCLUSÕES

O planejamento da manutenção tem impactos significativos no cumprimento dos objetivos da gestão de ativos em toda organização. A seleção de estratégias de manutenção adequadas pode contribuir para a produtividade, aumentando a disponibilidade operacional. No entanto, esta tarefa não é simples e os gestores devem combinar diferentes abordagens de acordo com o contexto de suas organizações e as expectativas das partes interessadas para atingir seus objetivos.

Devido às tecnologias disponíveis e à crescente complexidade dos sistemas utilizados, a MBC tem se destacado entre as estratégias de manutenção. Por meio dessa, a manutenção pode monitorar e rastrear o estado dos ativos e propor intervenções no momento mais adequado. Além disso, a MBC contribui para o controle dos riscos associados a potenciais falhas, garantindo uma operação mais segura. Com grande importância em uma estratégia de MBC, processos de DDF precisam ser implementados com sucesso. Nesse contexto, o presente trabalho propõe uma estrutura híbrido para automatizar o processo de DDF baseado em duas técnicas não supervisionadas de aprendizado de máquina e no conhecimento sobre o sistema analisado.

O trabalho propõe um estudo de caso no qual a estrutura proposta é aplicada a um modelo simplificado de hidrogerador, baseado em uma unidade geradora real, para sua validação. Como principais resultados, foi possível integrar a base de conhecimento disponível, organizada durante o processo de estudo do sistema, servindo como input para os demais processos do método. Posteriormente, a detecção e o diagnóstico para três diferentes modos de falha simulados, incluindo falhas mecânicas e de sensores, foram realizados com sucesso, demonstrando a capacidade do método, que futuramente poderá ser aplicado a condições reais.

REFERÊNCIAS

- [1] Ahuja IPS, Khamba JS. Total productive maintenance: Literature review and directions. *International Journal of Quality and Reliability Management* 2008;25:709–56. <https://doi.org/10.1108/02656710810890890>.
- [2] Ithemegbulem I, Baglee D. ISO55000 standard as a driver for effective maintenance budgeting. 2nd International Conference on Maintenance Engineering, IncoME-II 2017, The University of Manchester, UK: 2017, p. 16.
- [3] Arunraj NS, Maiti J. Risk-based maintenance - Techniques and applications. *Journal of Hazardous Materials* 2007;142:653–61. <https://doi.org/10.1016/j.jhazmat.2006.06.069>.
- [4] Khan FI, Haddara MM. Risk-based maintenance (RBM): A quantitative approach for maintenance/inspection scheduling and planning. *Journal of Loss Prevention in the Process Industries* 2003;16:561–73. <https://doi.org/10.1016/j.jlp.2003.08.011>.
- [5] Wisniewski Z, Blaszczyk A. Changes in Maintenance Management Practices - Standards and Human Factor. *Advances in Intelligent Systems and Computing*, vol. 606, 2018, p. 348–54. https://doi.org/10.1007/978-3-319-60474-9_32.
- [6] Sobral J, Guedes Soares C. Preventive Maintenance of Critical Assets based on Degradation Mechanisms and Failure Forecast. *IFAC-PapersOnLine* 2016;49:97–102. <https://doi.org/10.1016/j.ifacol.2016.11.017>.
- [7] Jardine AKS, Lin D, Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing* 2006;20:1483–510. <https://doi.org/10.1016/j.ymsp.2005.09.012>.
- [8] Isermann R. *Fault-Diagnosis Applications Model-Based Condition Monitoring*. 2011.
- [9] Michalski MA de C, Melani AH de A, Silva RF da, Souza GFM de, Nabeta SI, Hamaji FH. Applying Moving Window Principal Component Analysis (MWPCA) for Fault Detection in Hydrogenerator. In: Baraldi P, Maio F di, Zio E, editors. *Proceedings of the 30th European Safety and Reliability Conference and the 15th Probabilistic Safety Assessment and Management Conference*, Venice: Research Publishing, Singapore; 2020, p. 8.
- [10] Melani AH de A, Michalski MA de C, da Silva RF, de Souza GFM. A framework to automate fault detection and diagnosis based on moving window principal component analysis and Bayesian network. *Reliability Engineering & System Safety* 2021;215:107837. <https://doi.org/10.1016/j.ress.2021.107837>.
- [11] Venkatasubramanian V, Rengaswamy R, Yin K, Kavuri SN. A review of process fault detection and diagnosis Part I: Quantitative model-based methods. *Computers & Chemical Engineering* 2003;27:293–311.
- [12] Venkatasubramanian V, Rengaswamy R, Kavuri SN. A review of process fault detection and diagnosis part II: Qualitative models and search strategies. *Computers and Chemical Engineering* 2003;27:313–26. [https://doi.org/10.1016/S0098-1354\(02\)00161-8](https://doi.org/10.1016/S0098-1354(02)00161-8).
- [13] Venkatasubramanian V, Rengaswamy R, Yin K, Kavuri SN. A review of fault detection and diagnosis. Part III: Process history based methods. *Computers and Chemical Engineering* 2003;27:327–46.
- [14] Alauddin M, Khan F, Imtiaz S, Ahmed S. A Bibliometric Review and Analysis of Data-Driven Fault Detection and Diagnosis Methods for Process Systems. *Industrial and Engineering Chemistry Research* 2018;57:10719–35. <https://doi.org/10.1021/acs.iecr.8b00936>.
- [15] Khorasgani H, Farahat A, Ristovski K, Gupta C, Biswas G. A Framework for Unifying Model-based and Data-driven Fault Diagnosis. *PHM Society Conference* 2018;10:1–10.
- [16] Adedigba SA, Khan F, Yang M. Dynamic failure analysis of process systems using principal component analysis and Bayesian network. *Industrial and Engineering Chemistry Research* 2017;56:2094–106. <https://doi.org/10.1021/acs.iecr.6b03356>.

- [17] Shi H, Guo J, Bai X, Guo L, Liu Z, Sun J. Gearbox Incipient Fault Detection Based on Deep Recursive Dynamic Principal Component Analysis. *IEEE Access* 2020;8:57646–60. <https://doi.org/10.1109/ACCESS.2020.2982213>.
- [18] Yin S, Li X, Gao H, Kaynak O. Data-Based Techniques Focused on Modern Industry: An Overview. *IEEE Transactions on Industrial Electronics* 2015;62:657–67. <https://doi.org/10.1109/TIE.2014.2308133>.
- [19] Amin MT, Imtiaz S, Khan F. Process system fault detection and diagnosis using a hybrid technique. *Chemical Engineering Science* 2018;189:191–211. <https://doi.org/10.1016/j.ces.2018.05.045>.
- [20] Amin MT, Khan F, Imtiaz S, Ahmed S. Robust Process Monitoring Methodology for Detection and Diagnosis of Unobservable Faults. *Industrial and Engineering Chemistry Research* 2019;58:19149–65. <https://doi.org/10.1021/acs.iecr.9b03406>.
- [21] Wu G, Tong J, Zhang L, Zhao Y, Duan Z. Framework for fault diagnosis with multi-source sensor nodes in nuclear power plants based on a Bayesian network. *Annals of Nuclear Energy* 2018;122:297–308. <https://doi.org/10.1016/j.anucene.2018.08.050>.
- [22] Wang Z, Wang L, Liang K, Tan Y. Enhanced chiller fault detection using Bayesian network and principal component analysis. *Applied Thermal Engineering* 2018;141:898–905. <https://doi.org/10.1016/j.applthermaleng.2018.06.037>.
- [23] Sturlaugson LE, Sheppard JW. Principal component analysis preprocessing with Bayesian networks for battery capacity estimation. *Conference Record - IEEE Instrumentation and Measurement Technology Conference 2013:98–101*. <https://doi.org/10.1109/I2MTC.2013.6555389>.
- [24] Cai B, Zhao Y, Liu H, Xie M. A Data-Driven Fault Diagnosis Methodology in Three-Phase Inverters for PMSM Drive Systems. *IEEE Transactions on Power Electronics* 2017;32:5590–600. <https://doi.org/10.1109/TPEL.2016.2608842>.

DADOS BIOGRÁFICOS

(1) MIGUEL ANGELO DE CARVALHO MICHALSKI



Engenheiro mecânico graduado pela UFRJ no ano de 2001, tendo obtido o título de Mestre em Ciências, em Engenharia Mecânica, pela COPPE-UFRJ em 2004 e o título de Doutor em Ciências, em Engenharia Mecânica, pela Poli-USP em 2021. Atualmente é pesquisador no programa de Pós-doutorado da Poli-USP. Possui experiência nas áreas de energia e engenharia, tendo gerenciado e participado de projetos de P&D especialmente voltados a atividades relacionadas a monitoração de máquinas e equipamentos, detecção e diagnose de falhas, análise de dados, vibrações mecânicas, máquinas rotativas, dinâmica de rotores, processamento de sinais e confiabilidade de sistemas mecânicos.

(2) ARTHUR HENRIQUE DE ANDRADE MELANI

Arthur Henrique de Andrade Melani é engenheiro e pesquisador acadêmico brasileiro. Graduiu-se (2013) como Engenheiro Mecatrônico pela Universidade de São Paulo e possui mestrado (2015) e doutorado (2020) em Engenharia Mecânica pela mesma universidade. Desde sua graduação, ele tem participado ativamente de diversos projetos de pesquisa em Manutenção Centrada em Confiabilidade, Detecção e Diagnóstico de Falhas e Gerenciamento de Ativos. Sua pesquisa tem sido aplicada principalmente no setor de geração de energia, especialmente em usinas hidrelétricas e termelétricas. Atualmente é pós-doutorando na Escola Politécnica da Universidade de São Paulo.

(3) RENAN FAVARÃO DA SILVA

Renan Favarão da Silva é mestre em Engenharia Mecânica na área de Engenharia de Manufatura pela Universidade Tecnológica Federal do Paraná (UTFPR), Especialista em Engenharia da Confiabilidade (UTFPR) e Engenheiro Mecânico pela Universidade Estadual Paulista (UNESP). Atualmente está concluindo o doutorado pela Universidade de São Paulo (USP) em Engenharia Mecânica. Tem experiências profissionais e acadêmicas nas áreas de manutenção, confiabilidade e gestão de ativos.

(4) GILBERTO FRANCISCO MARTHA DE SOUZA

Professor Associado do Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos da Escola Politécnica da Universidade de São Paulo. Possui doutorado em Eng. Mecânica pela USP e executa pesquisas na área de confiabilidade, manutenção e análise de risco de sistemas eletromecânicos. Coordena projetos de pesquisa junto a empresas de geração de energia elétrica visando a análise de disponibilidade de sistemas de geração, incluindo a melhoria deste indicador com o emprego de técnicas de gestão de ativos, ressaltando-se a implantação das filosofias de Manutenção Centrada em Confiabilidade e Baseada em Risco, com ênfase em técnicas inteligentes de detecção e diagnose de defeitos.