

Sistema de Inferência Fuzzy para Diagnóstico de Desempenho de Turbinas a Gás Aeronáuticas

Tairo Teixeira¹, Ricardo Tanscheit¹, Marley Velasco¹,

¹Departamento de Engenharia Elétrica – PUC-Rio,
Rua Marquês de S. Vicente, 255, Gávea, Rio de Janeiro, RJ - Brasil – 22451-900

tairo.teixeira@gmail.com, {ricardo, marley}@ele.puc-rio.br

Resumo. Este trabalho propõe um Sistema de Inferência Fuzzy com extração automática de regras para diagnóstico de desempenho de turbinas a gás aeronáuticas. O sistema faz uso de uma abordagem residual – medições da turbina real são comparadas frente a uma referência de turbina saudável – para tratamento dos dados brutos de entrada para os módulos de detecção e isolamento, que, de forma hierárquica, são responsáveis por detectar e isolar falhas em níveis de componentes, sensores e atuadores. Como dados reais de falhas em turbinas a gás são de difícil acesso e de obtenção cara, a metodologia é validada frente a uma base de dados de falhas simuladas por um software especialista. Os resultados mostram que o SIF é capaz de detectar e isolar falhas corretamente, além de fornecer interpretabilidade linguística, característica importante no processo de tomada de decisão no contexto de manutenção.

Palavras-Chave. Lógica Fuzzy, Diagnóstico de Falhas, Turbina a Gás, Interpretabilidade, Extração de Regras, Confiabilidade.

1 Introdução

Intervenções não programadas devidas a uma falha arbitrária são causa direta de prejuízo em instalações industriais. A confiabilidade tem sido um aspecto importante na avaliação de produtos e/ou equipamentos industriais. Um equipamento bem projetado oferece alto nível de confiabilidade, mas, independentemente de quão bom seja o projeto, este sempre irá se deteriorar com o tempo. Neste contexto, a manutenção surge como uma maneira eficiente de garantir níveis aceitáveis de confiabilidade e qualidade durante o tempo de vida útil de equipamentos industriais [1].

A literatura de diagnóstico de desempenho de turbinas a gás é vasta e vem atraindo grande interesse da comunidade científica [2], [3]. Recentemente, fabricantes vêm adotando estratégias de Manutenção CBM (*Condition-Based Maintenance*), possibilitando determinar a saúde do equipamento por meio de sistemas de análise de dados inteligentes, com o objetivo de realizar intervenções de manutenção apenas quando necessário, ou simplesmente aumentar os períodos de intervenção programada.

Turbinas a gás são equipamentos muito complexos e caros. Por exemplo, o total de peças para uma turbina a gás industrial e seus auxiliares pode chegar a 20.000 e o seu custo a milhões de dólares [4], não mencionando as perdas indiretas que, normalmente, são maiores. Portanto, é fundamental que turbinas a gás tenham um sistema eficiente de monitoramento e diagnóstico, principalmente no Brasil, onde a frota de tais turbinas tem crescido muito nos últimos anos, devido, principalmente, ao aumento do número de usinas termelétricas e ao crescimento da aviação civil.

As técnicas mais populares de Inteligência Computacional (IC), além de Lógica Fuzzy [5]–[7], para diagnóstico de falhas em turbinas a gás são Redes Neurais Artificiais (RNA) [8], [9], Sistemas Especialistas (SE) [10], [11], Algoritmos Evolucionários (AE) [12] e técnicas híbridas [13], [14].

Este trabalho aborda o desenvolvimento e utilização de um Sistema de Inferência Fuzzy para diagnóstico de desempenho de turbinas a gás aeronáuticas. As regras são geradas a partir de dados de falhas simulados pelo software ProDiMES [2].

A metodologia proposta apresenta as seguintes características: (i) identificação de falhas em nível de componentes, sensores e atuadores; (ii) leva em consideração a influência temporal na evolução da falha; (iii) lida com o problema de diagnóstico de forma hierárquica, por meio das etapas de detecção e isolamento de falhas. A indicação de presença de uma falha vem acompanhada de quais regras foram ativadas, fornecendo ao especialista mais informação e um melhor direcionamento do que um sistema de diagnóstico típico forneceria.

2 Diagnóstico de Desempenho usando Lógica Fuzzy

A Fig. 1 mostra a arquitetura do sistema de diagnóstico de desempenho de turbinas a gás. Os dados de operação do equipamento monitorado são encaminhados para o módulo de pré-processamento, responsável por corrigir, gerar os resíduos, filtrar e normalizar os dados. Os dados pré-processados passam, então, pelo módulo de detecção e isolamento de falhas que, no treinamento, gera automaticamente as regras fuzzy via método de Wang-Mendel. Na fase de teste, as regras previamente geradas predizem o estado de saúde da turbina.

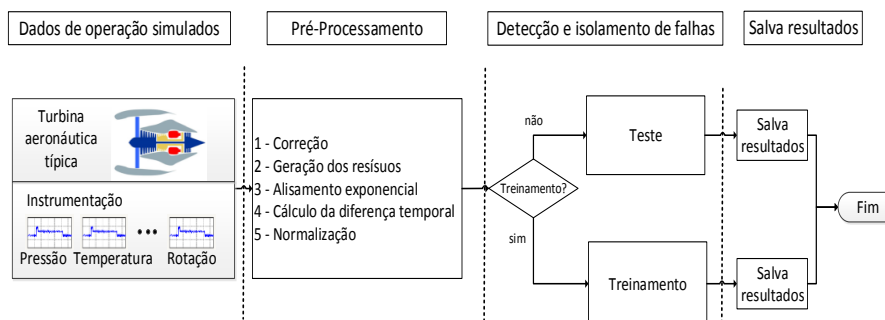


Fig. 1. Arquitetura do sistema

2.1 Pré-Processamento

O pré-processamento de dados (Fig. 2) coloca os dados em um formato mais adequado ao módulo de detecção e isolamento de falhas. Os procedimentos realizados nessa etapa tendem a melhorar consideravelmente os resultados finais.

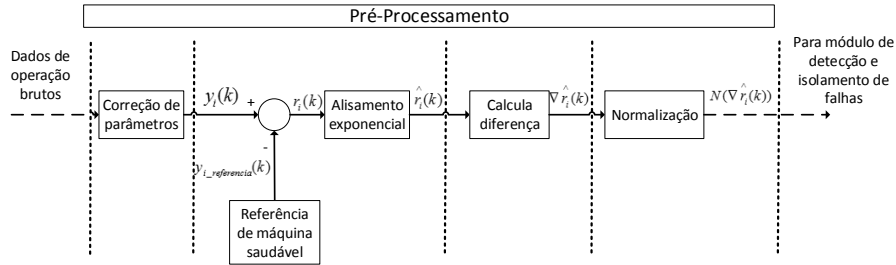


Fig. 2. Etapas do módulo de pré-processamento de dados.

Correção

Os parâmetros presentes ao longo do caminho do gás – temperaturas, pressões, vazões e rotações – variam não apenas com o patamar de potência, mas também com as condições ambientais. Uma vez que mudanças em parâmetros de entrada provocam mudanças nos valores ao longo do caminho do gás, a caracterização das relações aerodinâmicas entre os parâmetros do motor torna-se difícil se as condições ambientais não forem consideradas. Este problema é usualmente resolvido pela correção dos parâmetros do motor [15].

Dentro do contexto de diagnóstico, a correção de todos os parâmetros do motor é um passo inicial no pré-processamento e permite a comparação, em condições de operação diferentes, dos dados que serão usados em análise futura.

A correção dos parâmetros ao longo de uma turbina é realizada por [2], [15]:

$$Parâmetro_{corrigido} = \frac{Parâmetro}{\theta^a \delta^b} \quad (1)$$

onde os termos de correção de temperatura e pressão, θ e δ respectivamente, são definidos como:

$$\theta = \frac{T2(^{\circ}R)}{518.67} \quad (2)$$

$$\delta = \frac{P2(psia)}{14.696} \quad (3)$$

Os valores para a e b na equação (1) variam de acordo com o tipo e ciclo do motor, mas há valores clássicos presentes na literatura que são boas aproximações e usados na prática para turbinas a gás [2].

Geração dos Resíduos

É necessário usar uma abordagem de monitoramento de série temporal dos parâmetros da saúde do motor para capturar mudanças graduais de desempenho da turbina na forma de resíduos ou desvios de medições em relação a uma referência de máquina saudável. Esta referência é criada simulando-se turbinas saudáveis para um envelope abrangente de operação e variando as condições ambientais e de contorno como altitude, pressão e número de Mach. Portanto, a referência se constitui em uma tabela com os resultados corrigidos de simulação de turbinas saudáveis.

Dados coletados e corrigidos, para cada turbina em cada voo, são comparados a uma referência de máquina saudável, produzindo desvios de medição aqui tratados como resíduos $r_i(k)$, conforme:

$$r_i(k) = y_i(k) - y_{i_referencia}(k) \quad (4)$$

onde $y_i(k)$ é valor corrigido da i -ésima medição durante o k -ésimo voo e $y_{i_referencia}(k)$ é o valor de referência de máquina saudável nas mesmas condições de voo para as quais $y_i(k)$ foi coletado.

Alisamento Exponencial

Para suavizar a série temporal e minimizar o impacto de dados ruidosos e espúrios, um alisamento exponencial simples (AES) é aplicado aos resíduos calculados pela equação (4), conforme a equação [13]:

$$\hat{r}_i(k) = \alpha \cdot r_i(k) - (1 - \alpha) \cdot \hat{r}_i(k - 1) \quad (5)$$

onde $\hat{r}_i(k)$ é o valor residual alisado da i -ésima medição durante o k -ésimo voo e α é a constante de alisamento, $0 \leq \alpha \leq 1$. AES é uma média móvel ponderada que dá pesos maiores às observações mais recentes.

Diferença Temporal

É interessante, do ponto de vista de diagnóstico, detectar mudanças no comportamento da série que poderiam indicar o surgimento de uma falha. É esperado que o surgimento de uma falha cause rapidamente uma diferença nos valores observados entre uma turbina com falha no k -ésimo voo e uma turbina saudável no $(k - \beta)$ -ésimo voo. Esta comparação é realizada por meio do operador de diferença conhecido em técnicas de análise de séries temporais, chegando-se a:

$$\nabla \hat{r}_i(k) = \hat{r}_i(k) - \hat{r}_i(k - \beta) \quad (6)$$

onde $\nabla \hat{r}_i(k)$ é a diferença entre o valor residual alisado da i -ésima medição entre o k -ésimo voo e um voo $(k - \beta)$ anterior.

Normalização

A etapa de normalização é o último passo da etapa de pré-processamento. Uma forma padrão de normalização é dada por:

$$N(y_i) = \frac{y_i(k) - \mu_i(k)}{\sigma_i(k)}, \forall i \quad (7)$$

onde, para a i -ésima medição durante o k -ésimo voo, $y_i(k)$ é o valor corrigido, $\mu_i(k)$ e $\sigma_i(k)$ são a média e o desvio padrão do valor corrigido. Note-se que, na equação (4), usa-se a referência de máquina saudável. Isto é mais interessante no contexto de diagnóstico de falha, pois o objetivo é estabelecer uma diferença clara entre o equipamento saudável e aquele com falha. Assim, substituindo-se $\mu_i(k)$ pela referência de máquina saudável, $y_{i_referencia}(k)$, chega-se à seguinte normalização:

$$N(\nabla \hat{r}_i(k)) = \frac{\nabla \hat{r}_i(k) - \nabla \hat{r}_i(k - \beta)}{\sigma_i(k)} \quad (8)$$

onde $N(\nabla \hat{r}_i(k))$ é a diferença normalizada entre o valor residual alisado da i -ésima medição entre o k -ésimo voo e um voo ($k - \beta$) anterior, e $\sigma_i(k)$ é o desvio padrão do valor corrigido para i -ésima medição.

2.2 Detecção e Isolamento de Falhas

O módulo de detecção e isolamento de falhas (Fig. 3) é responsável tanto por gerar as regras fuzzy, no caso do treinamento, quanto por avaliar o estado de saúde da turbina, no caso de teste. Para a metodologia de diagnóstico de desempenho de turbinas a gás proposta neste trabalho, utiliza-se o já consagrado método de extração de regras fuzzy de Wang-Mendel [16].

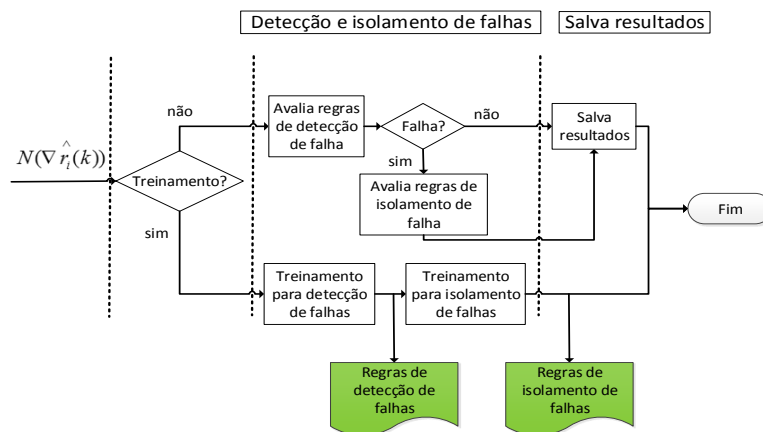


Fig. 3. Etapas do módulo de detecção e isolamento de falhas.

A Fig. 4 ilustra uma possível divisão do universo de discurso em três (a) ou cinco (b) regiões fuzzy. O conjunto fuzzy central, correspondente ao termo linguístico N, ou *negligenciável*, representa a região de resíduo próximo de zero – altamente associada à região em que o equipamento está saudável. O conjunto fuzzy identificado por r_{-N} representa os valores residuais negativos, enquanto r_{+N} representa os valores residuais positivos.

No caso de detecção de falhas, os conjuntos fuzzy de saída são definidos por duas funções de pertinência triangulares centradas em 0 (estado saudável) e em 1 (estado com falha). No caso de isolamento, o número de funções de pertinência triangulares é idêntico aos diferentes tipos de falhas.

A defuzzificação é realizada pelo método MOM (*Middle of Maximum*) que obtém uma medida de posição média do conjunto de maior grau de pertinência obtido. Como todos os conjuntos fuzzy das variáveis de saída são triangulares e simétricos, a saída defuzzificada assumirá os valores centrais dos conjuntos triangulares.

Como pode ser visto na Fig. 3, o sistema de diagnóstico proposto é hierárquico: (i) o sistema fuzzy de detecção de falha, após carregar a base de conhecimento gerada na etapa de treinamento, avalia a saúde da turbina apenas tentando prever se há uma falha; (ii) o sistema fuzzy para isolamento de falha, também após carregar a base de conhecimento gerada na etapa de treinamento, avalia o tipo de falha previamente detectada.

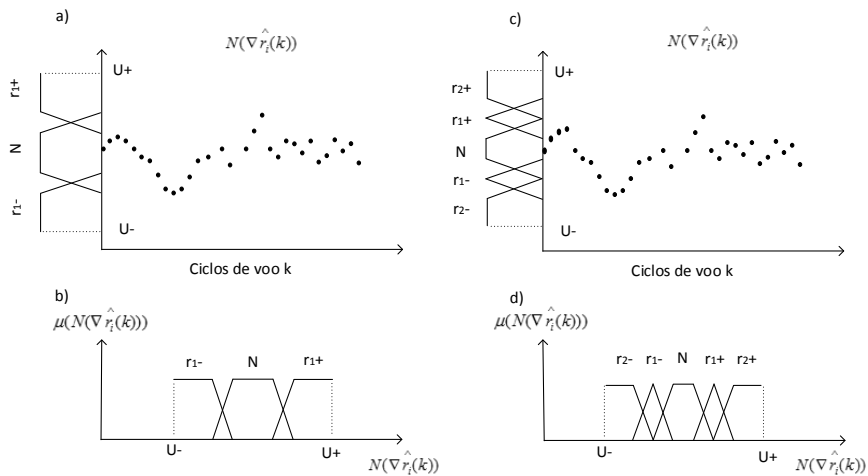


Fig. 4. Exemplo de inspeção dos valores para qualquer variável de entrada para definição dos limites inferior (U^-) e superior (U^+). a) divisão do domínio em 3 regiões; b) funções de pertinência correspondentes de (a); c) divisão do domínio em 5 regiões; d) funções de pertinência correspondentes de (c).

Para que o problema de diagnóstico possa ser avaliado corretamente, é desejável estabelecer métricas bem definidas. A seguir serão apresentadas algumas métricas típicas em tarefas de diagnóstico de falhas [17].

Verdadeiro Positivo (VP): número de detecções corretas de estados de falha dividido pelo total de casos de falha.

Verdadeiro Negativo (VN): número de detecções corretas de estados saudáveis dividido pelo número total de casos saudáveis.

Falso Positivo (FP): número de detecções incorretas de estados de falha dividido pelo total de casos de estados saudáveis. Esta métrica indica a frequência com que o algoritmo sugere que o equipamento está com falha, estando na verdade saudável.

Falso Negativo (FN): número de detecções incorretas de estados saudáveis dividido pelo total de casos de estados de falha.

Coefficiente de Kappa: medida da capacidade do algoritmo de classificar corretamente uma falha, levando em consideração o valor esperado de classificações corretas geradas pelo acaso [2]. Para um desempenho perfeito o coeficiente de Kappa é igual a um. Caso o algoritmo tenha desempenho de classificação pior do que o valor esperado gerado pelo acaso, seu coeficiente de Kappa é menor do que zero.

Percentual de Classificação Correta (PCC): número de classificações corretas de um tipo de falha dividido pelo total de casos deste tipo de falha.

3 Estudo de Caso

3.1 Base de Dados – ProDiMES

Para avaliação da metodologia proposta, os dados deste trabalho foram gerados pelo software ProDiMES [2], [17], [18]. Sua arquitetura inclui uma interface GUI (*Graphical User Interface*) que permite especificar entradas como número de turbinas, número de ocorrências de cada falha, número de voos simulados por turbina, voo do surgimento da falha, taxa de evolução da falha e geração dos dados com e sem ruídos. Contém um simulador de frota de turbinas a gás aeronáuticas do tipo turbofan e rotinas com diversas métricas de diagnóstico. A simulação da turbina, genérica do tipo turbofan, é realizada com o software C-MAPS-SS (*Commercial Modular Aeropropulsion System Simulation Steady-State*), que emula a aquisição de dados, fornecendo histórico dos parâmetros monitorados ao longo do caminho do gás. Um resumo dos tipos de falhas e suas distribuições uniformes de severidade é mostrada na Tabela 1.

Tabela 1. Tipos de falhas simuladas pelo ProDiMES

Falha	Severidade	Falha	Severidade	Falha	Severidade
Saudável	---	VBV	1 a 7%	T24	± 1 a 7% α
Fan	1 a 7%	Nf	± 1 a 7% α	T30	± 1 a 7% α
LPC	1 a 7%	Nc	± 1 a 7% α	T45	± 1 a 7% α
HPC	1 a 7%	P15	± 1 a 7% α	Wf	± 1 a 7% α
HPT	1 a 7%	P24	± 1 a 7% α	P24	± 1 a 7% α
LPT	1 a 7%	Ps30	± 1 a 7% α	T24	± 1 a 7% α
VSV	1 a 7%	---	---	---	---

As falhas Fan, LPC, HPC, HPT e LPT correspondem às falhas em componentes da turbina, VSV e VBV correspondem às falhas em atuadores e Nf, Nc, P15, P24, Ps30, T24, T30, T45, Wf, P24 e T24 correspondem às falhas em sensores. É importante lembrar que os sensores são as entradas para o sistema de diagnóstico aqui proposto.

3.2 Configuração do Sistema Fuzzy

Fazendo uso de uma base de dados gerada especificamente para avaliação do sistema, realizaram-se vários testes do tipo tentativa e erro para chegar à configuração mais adequada do Sistema de Inferência Fuzzy. Consideraram-se, nestes testes, 3, 5 e 7 conjuntos fuzzy para as variáveis de entrada, variando-se o tamanho da base superior do conjunto trapezoidal *negligenciável*.

As regras geradas são armazenadas em uma base de conhecimento e inspeccionadas com o objetivo de melhorar a interpretabilidade. Por exemplo, as três regras hipotéticas da Tabela 2, lado esquerdo, nas quais o conectivo *AND* é usado nos antecedentes, podem ser substituídas, por inspeção, pela única regra à direita, em que o conectivo *OR* é empregado na parte antecedente.

Tabela 2. Lado esquerdo – regras com o operador *AND*; Lado direito – regra com operador *OR*.

Antecedentes		Consequente	Operador
A	B	D	<i>AND</i>
B	A	D	<i>AND</i>
A	A	D	<i>AND</i>

➔

Antecedentes		Consequente	Operador
A	B	D	<i>OR</i>

A convenção adotada e a configuração final das variáveis de entrada são apresentadas na Fig. 5.

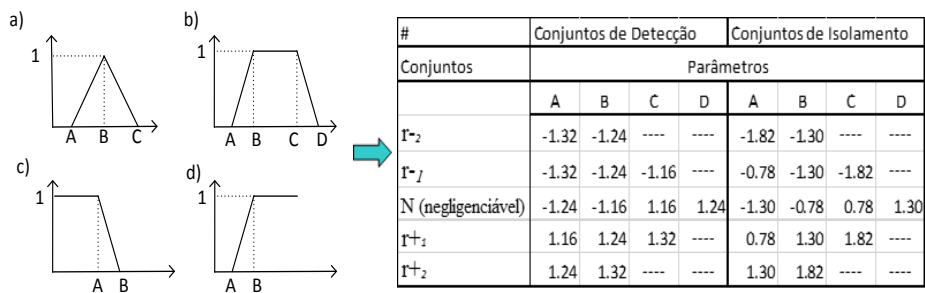


Fig. 5. Lado esquerdo: convenção adotada. a) função triangular; b) função trapezoidal; c) semi-trapézio à esquerda; d) semi-trapézio à direita. Lado direito: parâmetros

3.3 Experimentos e Resultados

A base de dados usada neste trabalho permite a comparação entre diferentes métodos de diagnóstico de desempenho de turbinas a gás aeronáuticas. Os resultados obtidos pela metodologia aqui proposta serão comparados aos de quatro métodos apresentados em [18]: Mínimos Quadrados Ponderados – MQP, Redes Neurais Probabilísticas – RNP, Ferramenta de Análise de Desempenho com Filtro de Kalman – FADFK e Observador/Estimador Genérico – OEG.

A Fig. 6 apresenta uma tabela com as métricas VP, FP e média de voos para alarme falso para os cinco métodos de diagnóstico, considerando todos os tipos de falhas, taxa de evolução e severidade. Os métodos apresentaram resultados muito próximos para a frequência de alarme falso, seguindo o limite de 1 alarme falso a cada 1000 voos. Isto permite uma justa comparação da métrica VP, que é dependente da taxa de alarme falso. É possível afirmar, portanto, que, apesar de nenhum dos métodos apresentar VP muito alto, o proposto neste trabalho apresenta acurácia de detecção semelhante aos métodos MQP e RNP, mas inferior às do FADFK e do OEG.

A Fig. 6 também apresenta a acurácia de detecção para diferentes severidades de falha (baixa, média e alta) e diferentes taxas de evolução de falha (abrupta e rápida). É possível afirmar que há uma tendência de melhor acurácia para falhas abruptas com severidade alta para todos os métodos de diagnóstico.




Fig. 6. Comparação de VP, FP e média de voos para alarme falso para os métodos MQP, RNP, FADFK, OEG e SIF e comparação da métrica VP para os métodos MQP, RNP, FADFK, OEG e SIF em função de diferentes naturezas de falhas.

Os resultados referentes ao Coeficiente de Kappa para os cinco métodos de diagnóstico são: 0.588 para o MQP, 0.59 para o RNP, 0.627 para o FADFK, 0.617 para o OEG e 0.517 para o SIF. Uma vez que o Coeficiente de Kappa é um reflexo da habilidade do algoritmo de isolar/classificar corretamente as falhas, pode-se afirmar que o SIF tem menor capacidade de isolamento, pois, mesmo apresentando acurácia de detecção semelhante às dos métodos MQP e RNP, sua acurácia no isolamento de falha é menor.

A Fig. 7 apresenta o PCC para os cinco métodos de diagnóstico em relação às falhas abruptas e rápidas, respectivamente. Tal como para o caso de detecção, falhas abruptas também tendem a ser mais facilmente isoladas que falhas rápidas, e é per-

ceptível que o método SIF apresenta PCC semelhante aos dos demais métodos para as falhas Fan, LPC, HPC, HPT, LPT, VSV, Nf e WF36. No entanto, para as falhas P24, Ps30, T24, T30, T48 e Pamb, o desempenho do SIF é inferior, indicando que, assim como expresso pelo Coeficiente de Kappa, sua capacidade de isolamento necessita de aprimoramento. No que diz respeito às falhas LPC, VBV, Nc, P2 e Pamb, houve dificuldade de diagnosticá-las, revelando que são inerentemente mais difíceis de detectar.

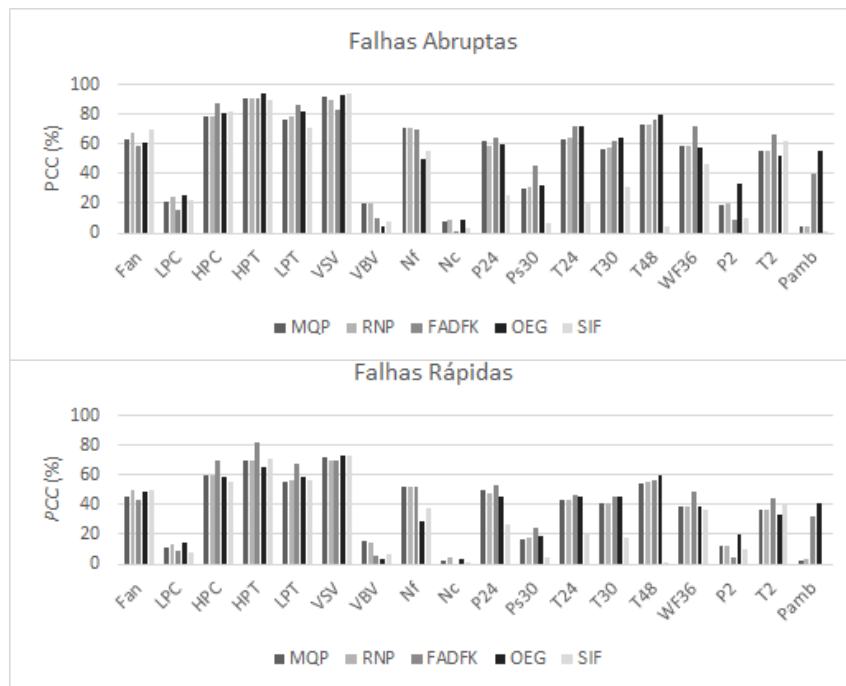


Fig. 7. Comparação da métrica PCC para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF para falhas abruptas.

Em relação à capacidade de diagnóstico para falhas em componentes, sensores e atuadores, pode-se dizer que, de modo geral, as falhas em nível de componente são mais fáceis de detectar, pois todos os métodos apresentaram bons resultados, exceto para falha no LPC; os algoritmos apresentaram bons resultados para falhas no atuador VSV, mas resultados ruins para falha no atuador VBV. Finalmente, em relação às falhas em sensores, há algumas de diagnóstico fácil (Nf, P24, T24, T30, T48, WF36 e T2) e outras nem tanto (Nc, Ps30, P2 e Pamb), embora o SIF tenha apresentado desempenho pior para falhas em sensores. É importante observar que nenhum dos métodos da literatura tem preocupação com interpretabilidade, característica atrativa no contexto de manutenção e explorada a seguir.

3.4 Interpretabilidade

Um SIF tem a propriedade de fornecer uma interpretabilidade linguística por meio das regras ativadas no processo de diagnóstico de falhas. Neste estudo de caso, apesar de o número máximo de regras possíveis ser de 78125 para detecção e para isolamento de falhas, foram geradas 193 regras para o primeiro caso e 1621 regras para o segundo. A Tabela 3 e a Tabela 4 exibem, respectivamente, exemplos de regras para detecção e isolamento de falhas ativadas durante a avaliação da falha no componente Fan. São mostrados, também, os conectivos usados na parte antecedente das regras.

Tabela 3. Regra ativada durante avaliação de falha Fan para o módulo de detecção de falha.

Nc	P24	Ps30	T24	T30	T48	Wf	Consequente	Operador
r2-	r2-	r2-	r2-	r2-	r2-	r2-	Falha	OR

Tabela 4. Regra ativada durante avaliação de falha Fan para o módulo de isolamento de falha.

Nc	P24	Ps30	T24	T30	T48	Wf	Consequente	Operador
r2-	r1-	r2-	N	r2-	r2-	r2-	Fan	AND

A descrição linguística é importante, pois permite concluir que houve, efetivamente, uma falha – pelo menos um dos parâmetros de entrada apresentou valores inferiores ao normal (referência saudável). E a falha é do tipo Fan, pois os parâmetros Nc, P24, Ps30, T30, T48 e Wf apresentaram valores inferiores ao normal, enquanto que o parâmetro T24 manteve-se dentro da normalidade.

4 Conclusão

Este trabalho, fundamentado principalmente em fornecer um enfoque de interpretabilidade linguística ao problema de diagnóstico de desempenho de turbinas a gás aeronáuticas, utilizou-se de um Sistema de Inferência Fuzzy com extração automática de regras via método Wang & Mendel. A partir de falhas simuladas por um software especialista, foi possível desenvolver os módulos de pré-processamento, detecção e isolamento de falhas, validá-los e comparar o seu desempenho com os de outros métodos disponíveis na literatura aberta de diagnóstico.

Como trabalhos futuros, pode-se citar: (i) otimização do módulo de isolamento, principalmente quanto à sua acurácia; (ii) como as etapas de ajuste manual dos SIFs de detecção e isolamento são extremamente custosas, seria aconselhável fazer uso de um otimizador como Algoritmos Genéticos para encontrar uma configuração ótima dos módulos. Sugere-se uma otimização multi-objetivo entre a métrica VP e alarme falso para o módulo de detecção e uma otimização simples do Coeficiente de Kappa para o módulo de isolamento.

5 Referências

1. Jardine, A.K.S., Lin, D., Banjevic, D.: A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance. *Mechanical Systems and Signal Processing*, 20, pp. 1483–1510 (2006).
2. Simon, D.L.: Propulsion Diagnostic Method Evaluation Strategy (ProDiMES) User's Guide (2010)
3. Jaw, L.: Recent Advancements in Aircraft Engine Health Management (EHM) Technologies and Recommendations for the Next Step. In: *ASME Turbo Expo Power Land, Sea, Air*, pp 683–695 (2005)
4. Loboda, I.: Gas Turbine Condition Monitoring and Diagnostics. *Gas Turbines* (2010)
5. Ganguli, R.: Application of Fuzzy Logic for Fault Isolation of Jet Engines. *J. Eng. Gas Turbines Power* 125, 617 (2003)
6. Marínai, L., Singh, R.: A Fuzzy Logic Approach to Gas Path Diagnostics in Aero-Engines. *Computational Intelligence in Fault Diagnosis*. Springer, pp 37–79 (2006)
7. Barbosa, R., Ferreira, S.: Industrial Gas Turbine Diagnostics using Fuzzy Logic. *ASME Turbo Expo 2012: Turbine Tech. Conf. Expo.*, pp. 803–808 (2012)
8. Volponi, J., DePold, H., Ganguli, R., Daguang, C.: The Use of Kalman Filter and Neural Network Methodologies in Gas Turbine Performance Diagnostics: a Comparative Study. *J Eng Gas Turbines Power* 125, 917 (2003)
9. Tayarani-Bathaie, S.S., Vanini, Z.N.S., Khorasani, K.: Dynamic Neural Network-Based Fault Diagnosis of Gas Turbine Engines. *Neurocomputing* 125, 153–165 (2014)
10. Zhao, N., Li, S., Cao, Y., Meng, H.: Remote Intelligent Expert System for Operation State of Marine Gas Turbine Engine. *11th IEEE World Congr. Intell. Control Autom. (WCICA)*, pp. 3210–3215 (2014)
11. Bo, M., Zhi-nong, J., Zhong-qing, W.: Development of the Task-Based Expert System for Machine Fault Diagnosis. *J. Phys: Conference Series*, 364, conf.1 (2012)
12. Ishibashi, R., Nascimento Jr, C.L.: GFRBS-PHM: A Genetic Fuzzy Rule-Based System for PHM with Improved Interpretability. *IEEE Conf. Prognostics and Health Management*, pp 1-7 (2013)
13. DePold, H.R., Gass, F.D.: The Application of Expert Systems and Neural Networks to Gas Turbine Prognostics and Diagnostics. *J. Eng. Gas Turb. Power*, 121, pp. 607-612 (1999)
14. Peel, L., Gold, I.: Data Driven Prognostics using a Kalman Filter Ensemble of Neural Network Models. *IEEE Conf. Prognostics and Health Management*, pp. 1–6 (2008)
15. Volponi, A.J.: Gas Turbine Parameter Corrections. *J. Eng. Gas Turbine Power*, 121, pp. 613-621 (1999)
16. Wang, L-X., Mendel, J.M.: Generating fuzzy rules by learning from examples. *IEEE Trans Syst Man Cybern* 22, pp. 1414–1427 (1992)
17. Simon, D.L., Bird, J., Davison, C., Volponi, A., Iverson, R.E.: Benchmarking Gas Path Diagnostic Methods: a Public Approach. *ASME Turbo Expo 2*, pp. 325–336 (2008)
18. Simon, D.L., Borguet., S, Léonard, O., Zhang, X.: Aircraft Engine Gas Path Diagnostic Methods: Public Benchmarking Results. *J Eng Gas Turbines Power*, 136, 10 pages (2013)