

DETECÇÃO DE ANOMALIAS EM UMA VÁLVULA PNEUMÁTICA USANDO MODELOS DE MISTURA DE GAUSSIANAS

JOÃO P. P. GOMES¹, LEONARDO R. RODRIGUES¹, ROBERTO K. H. GALVÃO², TAKASHI YONEYAMA²

1. EMBRAER S.A.

Av. Brigadeiro Faria Lima, 2170, Putim, São José dos Campos – SP, 12227-901

E-mails: joao.pordeus@embraer.com.br, leonardo.ramos@embraer.com.br

2. Departamento de Sistemas e Controle, Divisão de Engenharia Eletrônica, Instituto Tecnológico de Aeronáutica

Praça Marechal Eduardo Gomes, 50, Vila das Acácias, São José dos Campos – SP, 12228-900

E-mails: kawakami@ita.br, takashi@ita.br

Abstract— The high maintenance costs and the high availability indexes required by the aviation industry make it essential to optimize the usage of components installed in the aircraft. Anomaly detection techniques can be used in order to identify abnormal operational patterns and indicate whether a maintenance intervention is recommended. This work presents an anomaly detection methodology to be applied to pneumatic valves based on operational data measurements. The proposed methodology uses gaussian mixture models. An application example involving a real system is presented. The monitored component is a pneumatic valve used in an aircraft heat exchange system for pressure and temperature control. The results showed that the proposed methodology was able to identify functional anomalies in the monitored component.

Keywords— Health Monitoring, Gaussian Mixture Models, Pattern Recognition.

Resumo— Os altos custos de manutenção e os altos índices de disponibilidade exigidos na indústria aeronáutica tornam fundamental a otimização do uso dos equipamentos instalados nas aeronaves. Técnicas de detecção de anomalias podem ser usadas para identificar padrões anormais de operação e indicar se alguma intervenção de manutenção é recomendada. Este trabalho apresenta uma metodologia para detecção de anomalias em válvulas pneumáticas a partir de medições de dados de operação do sistema. A metodologia proposta usa modelos de mistura de gaussianas. Um exemplo envolvendo um sistema real é apresentado. O componente monitorado é uma válvula pneumática usada em um sistema aeronáutico de troca de calor para controle de pressão e temperatura. Os resultados obtidos mostraram que a metodologia proposta permitiu identificar anomalias no funcionamento do componente monitorado.

Palavras-chave— Monitoramento da Saúde, Modelos de Mistura de Gaussianas, Reconhecimento de Padrões.

1 Introdução

Os conceitos de monitoramento da saúde e prognóstico de falhas de sistemas têm se destacado nos últimos anos na comunidade aeronáutica como uma tecnologia que pode provocar um impacto significativo nas práticas de manutenção na aviação militar, comercial e executiva. Segundo Vachtsevanos *et al* (2006), o termo PHM (*Prognostic and Health Monitoring*) é comumente usado para se referir às técnicas que visam promover a capacidade de estimar o estado de saúde ou nível de degradação de um equipamento e antecipar falhas incipientes dos componentes monitorados.

Vários trabalhos foram publicados recentemente mostrando a aplicação, com sucesso, de técnicas de monitoramento da saúde em diferentes sistemas aeronáuticos. Por exemplo, Bizarría *et al* (2009) e Musiani *et al* (2007) apresentam, respectivamente, um método baseado em modelo para prognóstico de falhas em atuadores hidráulicos e uma plataforma para monitoramento da integridade estrutural de uma aeronave. Diferentes técnicas de PHM foram propostas

por Vieira *et al* (2009) e Vianna *et al* (2011) para monitoramento da saúde de uma APU (*Auxiliary Power Unit*). Propostas de metodologias de PHM para baterias foram propostas por Penna *et al* (2012) e Saha (2011). Sandborn (2005) apresenta uma aplicação de monitoramento da saúde equipamentos eletrônicos.

O sistema de controle de temperatura e pressão do ambiente é um dos sistemas críticos de uma aeronave. Em geral, uma quantidade relativamente alta de problemas nesse sistema é reportada, sendo que as válvulas pneumáticas do sistema são responsáveis por grande parte dos problemas. Gomes *et al* (2012) propôs uma metodologia para prognóstico de falhas em válvulas usando filtro de Kalman, entretanto a utilização de tal abordagem pressupõe a existência de um método capaz de detectar a falha ainda em estágio incipiente. Pode-se então sumarizar o processo de funcionamento de um sistema completo de monitoramento da seguinte forma: inicialmente um sistema de detecção de falhas incipientes é posto em funcionamento, a partir da detecção da falha, entra em funcionamento um sistema capaz de prever o instante da falha funcional (quando o equipamento não é mais capaz de cumprir a sua função).

O presente trabalho apresenta uma proposta de metodologia para detecção de falhas incipientes em válvulas pneumáticas, com o uso de modelos de mistura de gaussianas. Para esta tarefa utiliza-se o paradigma de detecção de anomalias.

2 Descrição do Sistema

O componente escolhido neste trabalho como objeto de estudo é uma válvula pneumática comumente usada em aplicações aeronáuticas. A Figura 1 mostra uma imagem da válvula escolhida.



Figura 1. Válvula monitorada

Na aplicação apresentada neste artigo, a válvula em estudo é usada em um sistema de controle de temperatura e pressão de uma aeronave, que está parcialmente representado na Figura 2.




Figura 2. Sistema de controle de temperatura

No sistema representado acima, a válvula monitorada controla a vazão do ar quente que é extraído do motor da aeronave. Essa vazão influencia a pressão e a temperatura do ar que é enviado para o sistema de controle de ambiente da aeronave. O ar quente extraído do motor, antes de ser enviado para o sistema de controle de ambiente, é resfriado através da troca de calor com o ar externo, que possui temperaturas baixas.

O mau funcionamento da válvula pode comprometer o desempenho do sistema de controle de ambiente da aeronave. A aeronave possui dois sistemas redundantes para controle do ambiente. Quando um dos sistemas apresenta falha a aeronave ainda pode

operar, respeitando algumas restrições. Por exemplo, a altitude máxima de voo é permitida e reduzida, acarretando em aumento do consumo de combustível da aeronave.

Como mencionado anteriormente, a falha da válvula é precedida por variações de pressão e de temperatura que podem ser percebidas pela tripulação. Na próxima seção, será apresentada a metodologia proposta para monitorar a condição da válvula e antecipar a ocorrência de falhas com base em dados medidos do sistema.

3 Metodologia de Monitoramento

A abordagem de monitoramento adotada consiste na detecção de comportamentos anômalos da válvula pneumática. Esta abordagem consiste em coletar um conjunto de dados de válvulas não degradadas. A partir destes dados é desenvolvido um modelo capaz de caracterizar as válvulas em estado normal. De posse deste modelo, é possível testar um novo dado e verificar a sua semelhança com o modelo utilizado. O dado é dito anômalo se for suficientemente diferente do modelo.

Para a construção do modelo foram coletados dados provenientes de 1000 voos nos quais as válvulas estavam reconhecidamente em bom estado.

Para estes 1000 voos, foram obtidas medidas de temperatura e pressão do ar entregue ao sistema de controle de ambiente e velocidade de rotação do motor. As variáveis temperatura e pressão são diretamente afetadas pela atuação da válvula. A rotação do motor influencia na vazão de ar quente proveniente do motor. A partir destas medidas foram calculados 5 atributos: média da temperatura (x_1), variância da temperatura (x_2), média da pressão (x_3), variância da pressão (x_4) e média da rotação do motor (x_5). O conjunto das 1000 instâncias de vetores de 5 atributos compõe o conjunto de treinamento. Todos os atributos foram calculados quando a aeronave encontrava-se em cruzeiro.

Para o desenvolvimento do modelo foi escolhida uma abordagem estatística. Neste caso optou-se por modelar os dados através de uma distribuição de probabilidade.

Uma escolha usual consiste na modelagem utilizando uma distribuição gaussiana, com valores do vetor de médias e da matriz de covariância estimados a partir dos dados de treinamento. Esse modelo, porém, não se mostra adequado na aplicação aqui considerada, como pode ser constatado por inspeção da Figura 3. Nessa figura, os dados de treinamento são apresentados por meio de gráficos de espalhamento nos quais as variáveis monitoradas são confrontadas aos pares. Como se pode observar, a relação entre os diversos pares de variáveis não pode ser adequadamente aproximada por distribuições gaussianas. Por-

tanto, pode ser mais conveniente empregar uma outra alternativa para descrever a distribuição conjunta dos dados.




Figura 3. Confronto de todas as variáveis para o conjunto de treinamento.

Para a modelagem de dados não gaussianos pode-se adotar a estratégia de utilizar um modelo composto por distribuições gaussianas combinadas, também conhecido como modelo de mistura de gaussianas (MMG).

3.1 Modelos de Mistura de Gaussianas

Para o MMG a distribuição estimada é obtida através da combinação de k gaussianas. A distribuição resultante pode ser definida como:

$$p(\mathbf{x}) = \sum_{i=1}^k p(g=i) p(\mathbf{x} | g=i) \quad (1)$$

onde $p(g=i)$ representa a probabilidade *a priori* para cada gaussiana e $p(\mathbf{x} | g=i)$ representa a probabilidade de um dado \mathbf{x} pertencer à gaussiana i .

Através da utilização da equação da distribuição gaussiana multivariada para representar $p(\mathbf{x} | g=i)$ temos a seguinte expressão final:

$$p(\mathbf{x}) = \sum_{i=1}^k \pi_i C \exp \left[-\frac{1}{2} (\mathbf{x} - \mu_i)^T \Sigma_i^{-1} (\mathbf{x} - \mu_i) \right] \quad (2)$$

onde:

$$C = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} \quad (3)$$

e π_i representa a probabilidade *a priori* da gaussiana i .

Para estimação dos parâmetros μ_i , Σ_i e π_i foi aqui empregado o algoritmo *Expectation-Maximization* (EM). O algoritmo EM consiste em um método iterativo e pode ser dividido em duas etapas.

Durante a primeira etapa, são calculadas as probabilidades e_{ij} de cada dado \mathbf{x}_j pertencer a cada gaussiana i . A formulação utilizada é dada por:

$$e_{ij} = \sum_{i=1}^k \pi_i C \exp \left[-\frac{1}{2} (\mathbf{x}_j - \mu_i)^T \Sigma_i^{-1} (\mathbf{x}_j - \mu_i) \right] \quad (4)$$

Na a segunda etapa, os valores de μ_i , Σ_i e π_i são estimados de forma a maximizar a verossimilhança total dos dados de treinamento. Os valores são estimados de acordo com as equações abaixo:

$$\pi_i = \frac{\sum_{j=1}^M e_{ij}}{M} \quad (5)$$

$$\mu_i = \frac{\sum_{j=1}^M e_{ij} x_j}{\sum_{j=1}^M e_{ij}} \quad (6)$$

$$\Sigma_i = \frac{\sum_{j=1}^M e_{ij} (x_j - \mu_i)(x_j - \mu_i)^T}{\sum_{j=1}^M e_{ij}} \quad (7)$$

sendo M o número de pontos \mathbf{x}_j .

Após a segunda etapa, o processo é repetido até que os valores dos parâmetros converjam. Detalhes sobre o algoritmo EM podem ser encontrado em diversas referências como Duda *et al* (2000) e Webb (2002).

3.2 Aplicação da Metodologia

Para fins de comparação, durante o trabalho desenvolvido, os dados foram modelados de duas formas: utilizando uma distribuição gaussiana e utilizando um MMG.

A utilização dos dois modelos tem como objetivo verificar o real ganho obtido ao se modelar os dados utilizando o MMG quando comparado ao modelo com uma única gaussiana.

Para o modelo composto por uma gaussiana, o vetor de médias e a matriz de covariâncias foram estimados segundo as equações (8) e (9):

$$\mu = \frac{1}{M} \sum_j x_j \quad (8)$$

$$\Sigma = \frac{\sum_j (x_j - \mu)(x_j - \mu)^T}{M} \quad (9)$$

Para a aplicação do MMG, é necessária ainda a definição do número de gaussianas que irão compor o modelo. Para esta tarefa foi utilizado o critério de

informação Bayesiano (*Bayesian Information Criterion - BIC*).

A utilização deste critério baseia-se na minimização de um índice que pondera a verossimilhança entre dados e modelo e o número de gaussianas utilizado no modelo. A equação utilizada é apresentada a seguir:

$$BIC = -\ln p(\mathbf{x}) + \frac{1}{2}k(2d + 1)\ln n \quad (10)$$

onde d é a dimensão do vetor de atributos e n é o tamanho do conjunto de treinamento.

A estratégia então consiste em variar o número de gaussianas, verificar o resultado de (10) para cada modelo e escolher o modelo com o menor valor de (10). Para o problema em questão, a aplicação deste método resultou em um modelo composto por cinco gaussianas.

A partir da definição do número de gaussianas, pôde-se aplicar o algoritmo EM para a estimação dos parâmetros μ_i , Σ_i e π_i , para $i = 1, 2 \dots 5$.

Os modelos assim obtidos foram aplicados ao cálculo de valores de $p(\mathbf{x})$ para dados de novos voos, que não foram empregados durante o treinamento.

4 Resultados

Com o objetivo de analisar o desempenho dos modelos desenvolvidos, as figuras 4, 5, 6 e 7 apresentam um índice calculado como $-\log p(\mathbf{x})$ para diversos voos. Este índice, que pode ser usado para quantificar a dissimilaridade com respeito à condição de operação normal, será chamado de índice de degradação da válvula.

As figuras 4 e 5 apresentam o resultado da aplicação do modelo de uma gaussiana para duas aeronaves onde ocorreram problemas na válvula estudada. Já as figuras 6 e 7 apresentam o resultado da aplicação do MMG para as mesmas duas aeronaves.




Figura 4. Índice de degradação para a aeronave 1 – modelo com uma gaussiana




Figura 6. Índice de degradação para a aeronave 2 – modelo com uma gaussiana




Figura 6. Índice de degradação para a aeronave 1 – MMG




Figura 7. Índice de degradação para a aeronave 2 – MMG

Analisando as Figuras 3 e 4 é possível verificar a presença de picos no índice de degradação, o que indica um comportamento anômalo da válvula. A presença deste comportamento pode ser um indício de que o componente está próximo de falhar.

Tomando os registros de manutenção da aeronave, verificou-se a ocorrência de falhas nos voos 271 e

306 para as aeronaves 1 e 2 respectivamente. Este fato corrobora a hipótese levantada.

Observando agora os resultados das figuras 6 e 7 tem-se que o novo índice de degradação apresenta um aumento gradual até os voos em que foram reportadas as falhas. Após a ocorrência da falha, é possível verificar uma queda brusca no índice decorrente da troca do componente.

O fato do índice de degradação possuir aumento gradual é relevante pois este tipo de comportamento pode fornecer uma informação sobre quão degradado está a válvula e assim possibilitar ao operador da aeronave um melhor planejamento da manutenção.

Vale ainda ressaltar que, para as duas aeronaves, a falha ocorreu quando o índice obtido com o uso do MMG encontrava-se perto de 115. Tomando este valor como um limiar para o índice adotado, seria possível desenvolver um método para prever o instante de falha, seguindo linha similar à apresentada em Orchard *et al* (2009) e Gomes *et al* (2012).

5 Conclusões

Este artigo apresentou um estudo de caso envolvendo o monitoramento da condição de uma válvula aeronáutica. Para este propósito optou-se por uma abordagem baseada em detecção de anomalias tendo como base um modelo gaussiano e um modelo de mistura de gaussianas (MMG).

Foram utilizados dados de voo provenientes de válvulas em estado normal para o desenvolvimento dos modelos estatísticos. Os modelos propostos foram testados também com dados reais vindos de aeronaves que apresentaram falhas em suas válvulas.

Ambos os métodos apresentaram um aumento do índice de degradação quando as válvulas estavam prestes a falhar. Adicionalmente, o MMG apresentou um índice com aumento gradual, o que pode ser bastante útil em aplicações de previsão de instante de falha.

Agradecimentos

Os autores agradecem o apoio da FAPESP (processo 2011/17610-0) e CNPq (produtividade em pesquisa).

Referências Bibliográficas

- Bizarria, C. O. and Yoneyama, T. (2009). Prognostics and health monitoring for an electrohydraulic flight control actuator. Proceedings of the IEEE Aerospace Conference. Big Sky.
- Duda, R. O.; Hart, P. E. and Stork, D. G. (2000). Pattern Classification. New York: Wiley.
- Gomes J. P. P.; Galvão R. K. H. and Yoneyama T. (2012) Prognóstico de falhas em uma válvula pneumática utilizando filtro de Kalman. Anais

do Congresso Brasileiro de Automática. Campina Grande - PB.

- Musiani, D.; Lin, k. and Rosing, T. S. (2007). Active sensing platform for wireless structural health monitoring. Proceedings of the IEEE International Conference on Information Processing in Sensor Networks. Cambridge.
- Orchard M. E. and Vachtsevanos G. J. (2009). A particle-filtering approach for on-line fault diagnosis and failure prognosis. Transactions of the Institute of Measurement and Control, No. 31; pp. 221- 246.
- Penna, J. A. M.; Nascimento Jr. C. L. and Rodrigues, L. R. (2012). Health monitoring and remaining useful life estimation of lithium-ion aeronautical batteries. Proceedings of the IEEE Aerospace Conference. Big Sky.
- Sandborn, P. (2005). A decision support model for determining the applicability of Prognostic Health Management (PHM) approaches to electronic systems. Reability and Maintainability Symposium. Arlington.
- Saha, B. (2011). Battery health management system for electric UAVs. Proceedings of the IEEE Aerospace Conference. Big Sky.
- Vachtsevanos, G.; Lewis, F. L.; ROEMER, M.; HESS, A. and WU, B. (2006). Intelligent fault diagnosis and prognosis for engineering systems. New Jersey: Wiley.
- Vianna, W. O. L.; Gomes, J. P. P.; Galvão, R. K. H.; Yoneyama, T. and Matsuura, J. P. (2011). Health monitoring of an auxiliary power unit using a classification tree. Proceedings of the Annual Conference of the Prognostics and Health Management Society. Montreal.
- Vieira, F. M. and Bizarria, C. O. (2009). Health monitoring using support vector classification on an auxiliary power unit. Proceedings of the IEEE Aerospace Conference. Big Sky.
- Webb, A. (2002). Statistical Pattern Recognition. New York: Wiley.