

# Estimativa da Probabilidade de Falhas em Equipamentos Aeronáuticos

Guilherme Conceição Rocha, Karl Heinz Kienitz e Luiz Fabiano Damy

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

KONATUS, Praça Marechal-do-ar Eduardo Gomes, 50, Vila das Acácias, INCUBAERO, sala 2, São José dos Campos – SP, CEP 12228-901

**Resumo** — Este trabalho propõe uma metodologia genérica para se estimar a probabilidade de falhas em equipamentos aeronáuticos com base na série temporal de parâmetro indicativo da condição do equipamento. O algoritmo baseia-se numa técnica de Inteligência Artificial denominada Raciocínio Baseado em Casos e permite a implantação da Manutenção Baseada na Condição. O método é testado num estudo de caso real correspondente à estimativa de vida remanescente do motor Arriel 1M1 que equipa a aeronave SA365K Pantera da Aviação do Exército.

**Palavras-Chave** — diagnóstico, prognóstico, manutenção preditiva.

## I. MOTIVAÇÃO E OBJETIVO

A necessidade de se realizar o monitoramento contínuo e prognóstico de vida remanescente de equipamentos aeronáuticos é tema de vital importância para a racionalização manutenção desses. A partir deste monitoramento é possível adotar o paradigma da manutenção preditiva ou manutenção baseada na condição [2].

Atualmente a manutenção baseada na condição tem adquirido bastante popularidade em empresas aéreas principalmente por permitir a extensão do tempo entre intervenções de manutenção ou TBO (*Time Between Overhaul*) de diversos equipamentos, além de aumentar significativamente a segurança operacional da frota monitorada.

O objetivo do presente trabalho insere-se neste contexto e consiste em propor uma metodologia genérica para se estimar a probabilidade de falhas de equipamentos aeronáuticos com base na série temporal de parâmetro indicativo da condição do equipamento, utilizando uma técnica de Inteligência Artificial denominada Raciocínio Baseado em Casos.

## II. MODELO GENÉRICO DE DEGRADAÇÃO DO EQUIPAMENTO

Pode-se representar o modelo de evolução da condição de um determinado equipamento como um processo estocástico. De modo geral, tal modelo de evolução pode ser representado por uma série temporal não-estacionária de um parâmetro  $Y$  indicativo da condição do equipamento, conforme:

$$Y_t = T_t + \Pi_t + \Delta_t + Z_t. \quad (1)$$

O vetor  $Y_t$  corresponde à série temporal real da variável dependente,  $T_t$  e  $\Pi_t$  correspondem às componentes de tendência e sazonalidade, respectivamente,  $\Delta_t$  representa variáveis aleatórias discretas e  $Z_t$ , o resíduo aleatório.

Os termos de tendência podem ser escritos como:

$$T_t = \Phi_T B_T. \quad (2)$$

onde:  $T_t^T = [\tau_1 \ \tau_2 \ \dots \ \tau_n]$ ,  
 $B_T^T = [\beta_{T1} \ \beta_{T2} \ \dots \ \beta_{Tn}]$ ,  
 $\Phi_T = [\varphi_{T1} \ \varphi_{T2} \ \dots \ \varphi_{Tn}]$ , composta por vetores coluna  $\varphi_{T_i}$ ,  $i=1, 2, \dots, p$  contendo  $n$  elementos cada um,  $n$  é o número de elementos da série,  $p$  é a quantidade de variáveis aleatórias de tendência do modelo.

Os termos de sazonalidade podem ser escritos como:

$$\Pi_t = \Phi_S B_S. \quad (3)$$

onde:  $\Pi_t^T = [\pi_1 \ \pi_2 \ \dots \ \pi_n]$ ,  
 $B_S^T = [\beta_{S1} \ \beta_{S2} \ \dots \ \beta_{Sq}]$ ,  
 $\Phi_S = [\varphi_{S1} \ \varphi_{S2} \ \dots \ \varphi_{Sq}]$ , composta por vetores coluna  $\varphi_{S_i}$ ,  $i=1, 2, \dots, q$  contendo  $n$  elementos cada um,  $n$  é o número de elementos da série,  $q$  é a quantidade de variáveis aleatórias de sazonalidade do modelo.

Os termos de variáveis aleatórias discretas podem ser escritos como:

$$\Delta_t = \Phi_D B_D. \quad (4)$$

onde:  $\Delta_t^T = [\delta_1 \ \delta_2 \ \dots \ \delta_n]$ ,  
 $B_D^T = [\beta_{D1} \ \beta_{D2} \ \dots \ \beta_{Dr}]$ ,  
 $\Phi_D = [\varphi_{D1} \ \varphi_{D2} \ \dots \ \varphi_{Dr}]$ , composta por vetores coluna  $\varphi_{D_i}$ ,  $i=1, 2, \dots, r$  contendo  $n$  elementos cada um, definidos como,

$$\varphi_{D_i} = \begin{cases} 0, & t < t_{Di} \\ 1, & t \geq t_{Di} \end{cases}$$

$n$  é o número de elementos da série,

$r$  é a quantidade de variáveis aleatórias discretas do modelo.

### III. MÉTODO CBR EM DUAS CAMADAS

#### A. Descrição geral da metodologia

A metodologia utilizada de previsão de séries temporais em geral é baseado nos quatro Rs etapas do processo de Raciocínio Baseado em Casos (RBC), a saber [1] e [7]:

- Retrieve (recuperar)
- Reuse (reutilizar)
- Revise (revisar)
- Retain (reter)

Utiliza-se uma variante desta técnica denominada RBC em duas camadas [4], composto por uma camada externa denominada RBC de Cenários e uma camada interna chamada RBC de Progressão.

No RBC de Cenários, o objetivo é estimar a condição futura do sistema com base em um conjunto de variáveis exógenas que define o cenário atual. Por outro lado, no RBC de Progressão, o objetivo é estimar a condição futura do sistema baseado no conjunto de dados da série temporal correspondente ao cenário atual.

Um cenário é definido por um conjunto de variáveis exógenas capazes de representar as condições do ambiente externo ao sistema num determinado intervalo de tempo. Tais variáveis são também denominadas variáveis de cenário e podem ser representadas por meio de um vetor de cenários  $X$ .

A cada vetor de cenários  $X$  está associado um vetor de sintomas  $B_s$ , capaz de representar de modo compacto, a partir de um modelo pré-estabelecido, como a condição do sistema progride no tempo.

No escopo desse trabalho o vetor de sintoma  $B_s$  é igual ao vetor de coeficientes de tendência  $B_T$  definido em (2).

#### B. RBC de Cenários

Depois de uma mudança detectada nas variáveis exógenas, um cenário semelhante ao atual é recuperado na base de dados de cenários a partir do conjunto de variáveis exógenas (vetor  $X$ ). Associa-se a este cenário recuperado o vetor sintoma  $B_s$  do mesmo, o qual é reutilizado de modo a fornecer previsão inicial para a condição futura do sistema. À medida que mais dados são acumulados após a mudança nas variáveis exógenas, o modelo de previsão  $B$  proveniente do cenário mais próximo (vetor  $B_s$ ) pode ser mesclado com o modelo de previsão do RBC de Progressão CBR (vetor  $B_p$ ).

$$B = \alpha B_s + (1-\alpha) B_p . \tag{5}$$

A importância relativa do vetor sintoma do cenário mais próximo (vetor  $B_s$ ) diminui com o acúmulo de dados a respeito da séries temporal da condição do sistema dentro do cenário corrente. Isto pode ser modelado conforme abaixo:

$$\alpha = e^{-\lambda t} . \tag{6}$$

Um teste de hipótese é feito para verificar se tais mudanças nas variáveis exógenas tiveram contribuição

significativa sobre a modificação do vetor sintoma do atual cenário quando comparado com o cenário anterior.

#### C. RBC de Progressão

O RBC de Progressão é específico para um determinado cenário. O modelo de progressão é representado nesse processo pelo vetor sintoma  $B_p$ .

Determina-se o melhor modelo de progressão usando os dados de séries temporais como principal fonte de informações e determinando iterativamente o vetor sintoma que fornece as melhores previsões. A descrição desse algoritmo encontra-se detalhada em [4] e [5].

#### D. Integração entre RBC de Cenários e RBC de Progressão

As figuras a seguir descrevem como o RBC de Cenários se integra com o RBC de Progressão. As setas finas indicam fluxo do processo, enquanto as grossas representam troca de dados.

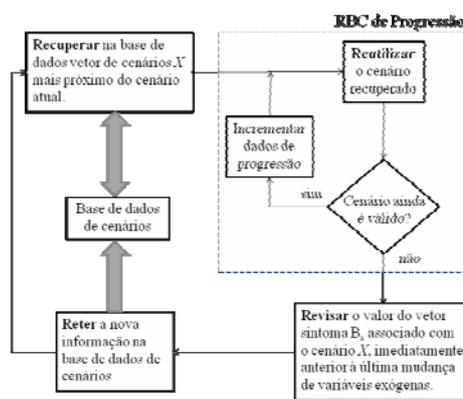


Fig. 1. RBC em duas camadas.

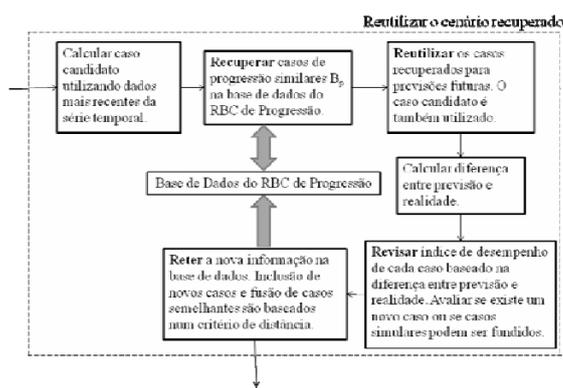


Fig. 2. Processo de reutilização do cenário recuperado.

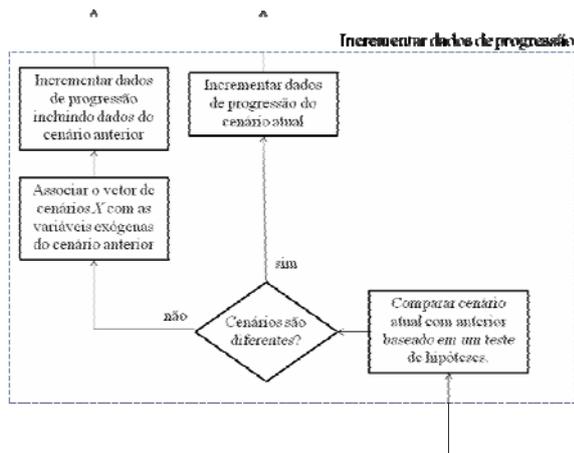


Fig. 3. Processo de incremento de dados de progressão mediante teste de hipótese.

#### IV. ESTIMATIVA DA PROBABILIDADE DE FALHA

A condição de falha do equipamento é definida pelo fato do valor de um parâmetro indicativo da condição do equipamento ultrapassar um determinado limite superior denominado limiar de falha. O valor do limiar de falha é conhecido a priori e pode ser interpretado como uma característica intrínseca do equipamento, como, por exemplo, uma lógica de monitoramento.

Deste modo, estimar a probabilidade de uma falha ocorrer corresponde a estimar qual a probabilidade do limiar de falha daquele equipamento ser ultrapassado. Na metodologia proposta neste trabalho, tal estimativa é feita considerando-se que a série temporal pode ser aproximada por um modelo conforme descrito em (1) apresentando resíduo gaussiano.

De modo resumido, pode-se afirmar que para realizar essa estimativa, as seguintes hipóteses devem ser satisfeitas:

- É possível construir uma série temporal de parâmetro indicativo da condição do equipamento;
- A série temporal é composta por pontos que representam o histórico de um equipamento antes da ocorrência de uma falha;
- É possível estabelecer um limiar de falha determinístico baseado em uma característica intrínseca da planta;
- É possível estabelecer um modelo de degradação do equipamento contendo resíduo gaussiano.

Ou seja, dado um ponto distante  $n$  iterações à frente do momento presente  $t$ , pretende-se estimar a probabilidade da série temporal  $y$  ter ultrapassado o limiar de falha entre os instantes  $t$  e  $t+n$ .

De modo genérico, em cada instante  $i$  iterações à frente do momento presente  $t$ , é possível estimar a probabilidade  $p_i$  do evento  $y_{t+i}$  ultrapassar o limiar de falha.

Ou seja, tem-se:

$$p_i = P(y_{t+i} > \text{limiar}). \quad (7)$$

Dado que foi considerado um resíduo gaussiano, esta estimativa de probabilidade é dada pela área sobre a curva, conforme representado na Fig. 4.

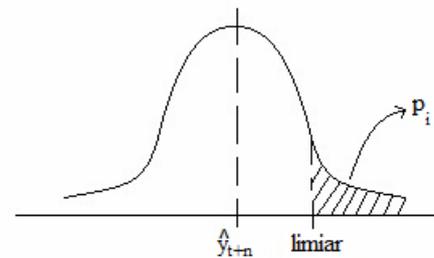


Fig. 4. Estimativa da probabilidade de falha.

Neste caso,  $y_{t+n}$  é uma variável aleatória contínua e a função densidade de probabilidade da mesma apresenta distribuição normal com média igual ao valor esperado para  $y_{t+n}$ , conforme representado na Fig. 4.

Finalmente, pode-se calcular para cada iteração  $i$  variando de 1 a  $n$  à frente do instante atual  $t$  a probabilidade de uma falha ter ocorrido. Neste caso, no instante  $n$  a função probabilidade acumulada de falha  $F_n$  é calculada através do complemento da função confiabilidade naquele instante ( $R_n$ ).

Teremos então:

$$F_n = 1 - R_n. \quad (8)$$

onde:

$$R_n = (1 - p_1) (1 - p_2) (1 - p_3) \dots (1 - p_n). \quad (9)$$

Percebe-se que a função  $F_n$  tem um comportamento monotonicamente crescente a cada iteração e tende a 1 quando a quantidade de iterações tende a infinito.

#### V. ESTUDO DE CASO

##### A. Característica do estudo de caso

Pretende-se estimar a probabilidade de ocorrência de falha no motor Arriel 1M1 que equipa a aeronave SA365K Pantera da Aviação do Exército.

As partes principais do motor são ilustradas na Fig. 5 e estão descritas na sequência abaixo [3]:

1. Entrada de ar
2. Compressor
3. Câmara de combustão
4. Turbina
5. Escapamento
6. Tomada de potência
7. Acionamento dos acessórios
8. Redutor de velocidade

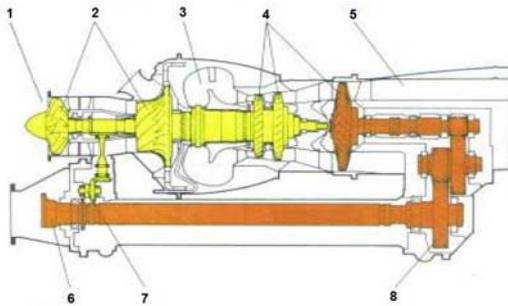


Fig. 5. Motor Arriel 1M1.

O motor Arriel 1M1 possui uma estrutura modular que facilita a manutenção em caso de falhas. No caso de falhas em qualquer um dos módulos, o mesmo pode ser facilmente separado do restante do motor e substituído.

Os helicópteros SA365K também são equipados com um sistema de monitoramento integrado de dados gravados em voo composto por sensores para medição de parâmetros, um gravador de dados e voz de cabine, uma unidade de exibição de informações para o piloto, uma unidade modular de análise de dados e uma estação de solo para armazenamento e análise das informações gravadas.

**B. Estimativa da condição do motor**

Escolheu-se como parâmetro indicativo da condição do motor um índice de eficiência térmica, calculado a partir da razão entre a temperatura após a câmara de combustão (T4) e a rotação da turbina geradora de gases (NG). A estimativa da condição do motor num determinado voo é dada pelo máximo valor que esta razão assume em condições de T4 e NG serem estacionários [6].

Na Fig.6 seguir ilustra-se o cálculo deste parâmetro por meio do registro de um voo normal.

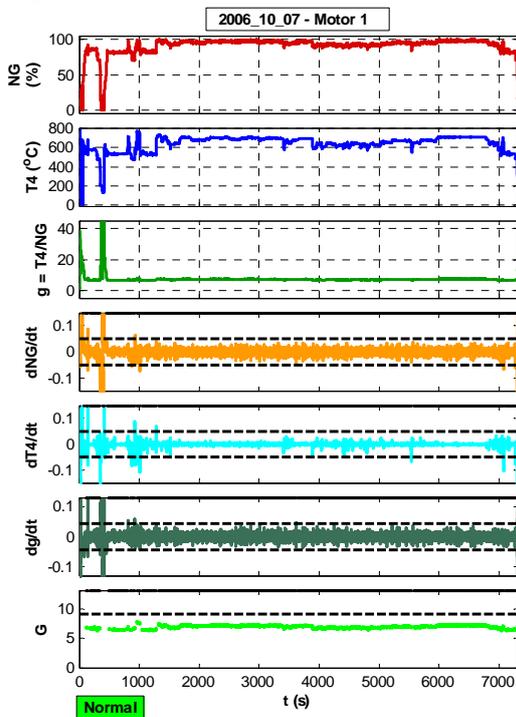


Fig. 6. Registro normal de voo.

**C. Hipóteses do problema**

A seguir são apresentadas as principais hipóteses do problema:

- Os limiares de alerta e falha são conhecidos a priori;
- Os termos de tendência da série temporal são modelados apenas como um ganho constante (função polinomial de ordem zero);
- As condições de falha têm natureza abrupta, não havendo degradação contínua com o tempo;
- As variáveis exógenas indicam se houve uma inspeção no equipamento *I* ou se o valor do parâmetro indicativo da condição do motor ultrapassou limiar de alerta *L*.

O vetor de cenários *X* é dado por:

$$X = [I \ L] . \tag{10}$$

onde:

*I* = 1, caso tenha havido inspeção recente do motor (há menos de 15 dias) e *I* = 0, caso contrário;

*L* = 1, caso o parâmetro indicativo da condição do motor tenha ultrapassado o limiar de alerta e *L* = 0, caso contrário.

A cada vetor de cenários está associado um vetor de sintomas *B<sub>s</sub>*. Dadas as hipóteses acima descritas, o vetor de sintomas será simplesmente um ganho constante.

$$B_s = \beta_0 = \text{cte} . \tag{10}$$

Deste modo, no teste de hipóteses, a hipótese nula e a alternativa correspondem respectivamente a:

- H0 – não há alteração no valor do ganho constante ( $\beta_0$ )
- HA – há alteração no valor do ganho constante

**D. Estudo de Caso Aeronave EB 2033**

Nesse caso, foram construídas as séries temporais do índice de eficiência térmica dos motores da aeronave EB 2033. Conforme observado na Fig. 7, o limiar de alerta foi ultrapassado pela primeira vez no dia 16/11/2006.

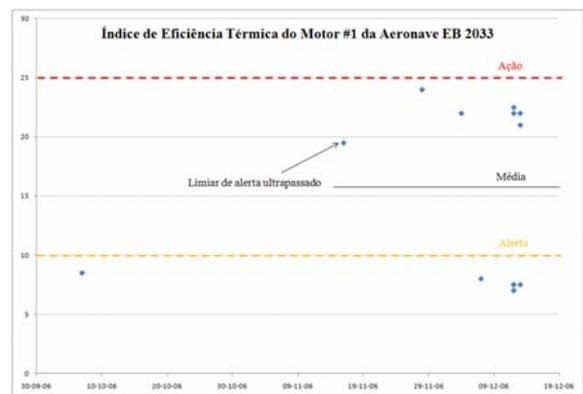


Fig. 7. Série Temporal do Motor #1 da Aeronave EB 2033.

Como não há registro de intervenções de manutenção no período, existem dois cenários distintos para o motor #1: um antes e outro após a ultrapassagem do limiar de alerta.

A tabela a seguir ilustra os cenários:

TABELA I CENÁRIOS CANDIDATOS PARA MOTOR #1 AERONAVE EB 2033

Início	Fim	Vetor Cenário (X)
07/10/2006	16/11/2006	[0 0]
16/11/2006	13/12/2006	[0 1]

Devido à insuficiência de dados da série temporal no primeiro cenário, o teste de hipóteses foi feito comparando-se informações do motor #1 após o limiar de alerta ter sido ultrapassado com o motor #2.

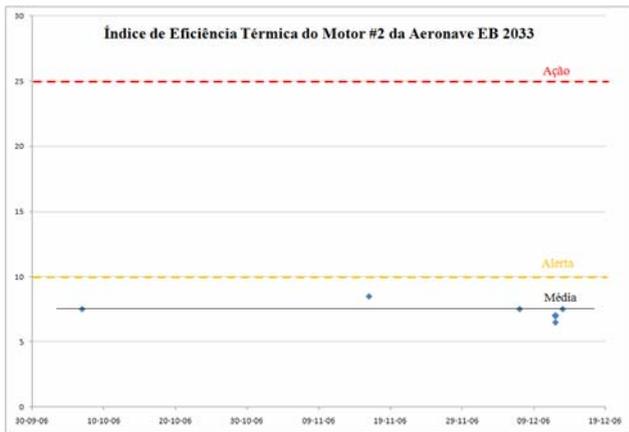


Fig. 8. Série Temporal do Motor #2 da Aeronave 2033.

O resultado do teste de hipóteses mostra que é possível rejeitar a hipótese nula e aceitar a hipótese alternativa, utilizando um nível de significância  $\alpha$  correspondente a 5% com bastante segurança. De fato, a estatística-teste z neste caso corresponde a 14.4, valor muito superior ao limite de 1.96 estabelecido para teste bicaudal com  $\alpha$  igual a 5%.

E. Estudo de Caso Aeronave EB 2036

Nesse caso, foram construídas as séries temporais do índice de eficiência térmica dos motores da aeronave EB 2036. Conforme observado na Fig. 9, em nenhum momento o limiar de alerta foi ultrapassado, porém há o registro de duas intervenções de manutenção. Esse fato permite que a série temporal de cada motor possa ser dividida em quatro cenários candidatos.

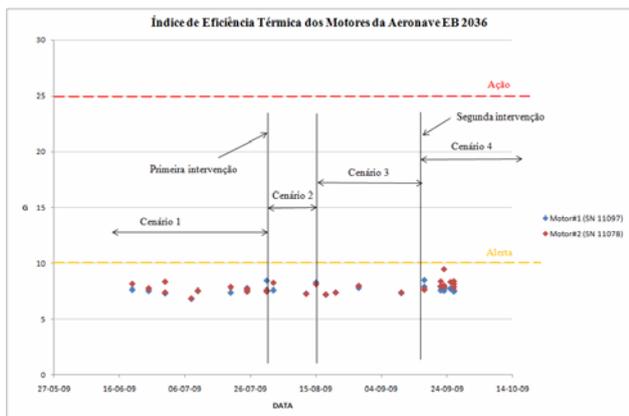


Fig. 9. Série Temporal dos Motores da Aeronave EB 2036.

A tabela a seguir ilustra os cenários candidatos para os motores da aeronave EB 2036:

TABELA II CENÁRIOS CANDIDATOS PARA AERONAVE EB 2036

Início	Fim	Vetor Cenário (X)
20/06/2009	29/07/2009	[0 0]
29/07/2009	13/08/2009	[1 0]
13/08/2009	16/09/2009	[0 0]
16/09/2009	26/09/2009	[1 0]

Apesar de existirem quatro cenários candidatos para cada motor da aeronave EB 2036, conforme exemplificados anteriormente, não foi possível, para um nível de significância correspondente a 5%, rejeitar a hipótese nula de que as intervenções de manutenção não tiveram influência significativa para o indicador de condição do motor, ou seja, os cenários candidatos fundem-se num único cenário, considerando toda a informação disponível na série temporal.

F. Estimativa da probabilidade

Para o motor #1 da aeronave EB 2033, adota-se o segundo cenário para se proceder com o prognóstico de falha do equipamento, visto que se trata do cenário mais recente. Para o motor #2 da mesma aeronave, utiliza-se toda a informação disponível na série temporal, visto que não houve mudança de cenário.

Como o modelo é dado por um valor constante acrescido de um desvio gaussiano, a cada iteração  $i$  após o instante atual  $t$ , a probabilidade de falha  $p_i$  mantém-se constante. Ou seja:

$$p_i = p = \text{cte.} \tag{10}$$

Com isso, estima-se a probabilidade de ter ocorrido uma falha  $F_n$  como:

$$F_n = 1 - (1 - p)^n \tag{11}$$

A Fig. 10 mostra como a probabilidade de falha evolui a cada vôo futuro para os motores da aeronave EB 2033. Percebe-se claramente a maior exposição ao risco de falha do motor #1.



Fig. 10. Probabilidade de Falha de Motores da Aeronave EB 2033.

Por outro lado, para os motores da aeronave EB 2036, estima-se que a probabilidade de ocorrer uma falha permaneça praticamente nula até que uma mudança de cenário significativa do ponto de vista de degradação do equipamento ocorra de fato.

## VI. CONCLUSÃO

Apresentou-se uma metodologia genérica para prover estimativas da probabilidade de falhas de diversos equipamentos aeronáuticos. Testou-se o método proposto no estudo de um modo de falha do motor Arriel 1M1, obtendo-se resultados coerentes.

Ressalta-se, porém, que, a fim de explorar toda a potencialidade da referida metodologia, é necessário se estabelecer bons indicadores da condição do equipamento, bem como limiares de falha bem definidos.

## REFERÊNCIAS

- [1] Aamodt, A. and Plaza, E. "Case-based reasoning: foundational issues", Methodological Variations, and System Approaches. AI Communications, Vol. 7, No.1, pp. 39–59, 1994
- [2] Ellis, B.A., "The Challenges of Condition Based Maintenance", [www.jethropeject.com](http://www.jethropeject.com), TJP, 2009, pp. 1-4
- [3] Lago, A.S., "O Emprego do Fly Data Recorder como Ferramenta de Manutenção Preditiva no Sistema de Monitoramento de Turbinas da Frota da Av Ex", Escola de Aperfeiçoamento de Oficiais, Trabalho de Conclusão de Curso, 2008
- [4] Rocha, G.C. and Kienitz, K.H., "System Forecast using a Case-Based Reasoning Methodology", artigo aceito para apresentação no congresso SMC2011 do IEEE, 2011
- [5] Rocha, G.C. et al, "Estimativa do Preço do Açúcar no Mercado de Commodities através de Método Iterativo Inspirado na Técnica de Raciocínio Baseado em Casos", UNINDU, 2008
- [6] Rocha, G.C. et al, "Desenvolvimento de um Sistema de Manutenção Baseada na Condição para o Comando de Aviação do Exército", XI SIGE, 2009
- [7] Watson, I. and Marir F., "Case-based reasoning: a review", The Knowledge Engineering Review, 1994