

UM ESTUDO DE CASO GENÉRICO DE DIAGNÓSTICO PREDITIVO PARA SISTEMAS COMPLEXOS

Reginaldo Inojosa da Silva Filho

Laboratório de Automação e Controle (LAC)
Escola Politécnica da Universidade de São Paulo – POLI/USP

Mariana Antonia Aguiar

Laboratório de Sistemas Integráveis (LSI) – Núcleo de Apoio à Pesquisa em Ciência Cognitiva (NAPCC)
Escola Politécnica da Universidade de São Paulo – POLI/USP

Zsolt L. Kovács

Laboratório de Automação e Controle (LAC)
Escola Politécnica da Universidade de São Paulo – POLI/USP

RESUMO

Este trabalho introduz os conceitos dos Sistemas Genéricos para Diagnóstico de Falhas e suas aplicações na manutenção de equipamentos aeronáuticos. As noções de Sistemas Complexos Diagnosticáveis bem como o processo de diagnóstico e sua classificação são mostrados sempre tendo como foco sua complexidade. Utilizando técnicas de Redes Neurais Artificiais para o diagnóstico preditivo de componentes que apresentam degradação em suas funcionalidades, a manutenção preventiva pode agir no momento oportuno para evitar um excessivo desgaste e a eventual parada do sistema considerado. Neste artigo, um estudo de caso considerando o sensor de ângulo de ataque de uma aeronave genérica é apresentado como componente possível de ser aplicado um Sistema de Diagnóstico Automático (SDA).

ABSTRACT

This paper presents an introduction to the concepts of General Systems for Fault Diagnosis and its applications to maintenance and its applications to aircraft maintenance. The basics of "Diagnosticable Complex Systems" as well as of the diagnostic processes and its classifications are presented focusing on their complexity. The application of artificial neural networks for prognosticating early wear and degradation of critical components is explored. A case study involving the diagnosis of Angle of Attack sensor of a generic aircraft is also developed.

1. INTRODUÇÃO

Com o avanço técnico e científico, as aplicações de engenharia no setor aeroespacial se tornam cada vez mais automatizadas e integradas, o que gera situações complexas de risco de falha. Aliado a esse fato, tem-se que a alta disponibilidade dos equipamentos torna-se um diferencial competitivo para as empresas do setor, tendo em vista ser esta cada vez mais exigida pelo aumento da demanda sobre os serviços fornecidos pela indústria aeroespacial.

Desta forma, o diagnóstico de falhas é um tema de relevância cada vez maior, não só do ponto de vista acadêmico mas empresarial, pelo seu aspecto econômico, na medida em que as ferramentas de diagnóstico se tornam um elemento premente a serem incorporados nos produtos aeronáuticos. Neste sentido, cabe salientar aqui a experiência trazida pelo FLD (*Flight Line Diagnostic*) desenvolvido pela Embraer em parceria acadêmica com a Escola Politécnica da Universidade de São Paulo (EPUSP).

Sistemas Diagnósticos Automáticos destinados à manutenção corretiva de equipamentos complexos possuem objetivos voltados, principalmente, ao aspecto econômico pois auxiliam

na redução de trocas desnecessárias de componentes, do tempo de diagnóstico e de rechamados (Aguiar, 2001). Porém, os Sistemas Automáticos que objetivam a manutenção preventiva englobam tanto o aspecto econômico, reduzindo os itens mencionados anteriormente, como também, e principalmente, os aspectos de segurança (*safety*) quando aplicável a sistemas complexos passíveis de comprometer a integridade de seus usuários, como os produtos aeronáuticos, pois o diagnóstico antecipado de uma falha pode, em muitos casos, sanar problemas que poderiam ser fatais ou altamente danosos aos seus usuários.

A Engenharia Diagnóstica tem uma visão fatalista: as falhas em Sistemas de Engenharia são inevitáveis, cabe então criar métodos eficientes para tratar sua correção.

Inicialmente, define-se a entidade mais importante na engenharia diagnóstica: o *Sistema Complexo Diagnosticável*. Os conceitos básicos de *diagnóstico*, *sintomas*, *falha* e *defeito* serão explicados em seguida e, posteriormente, a análise de um exemplo de diagnóstico preditivo será realizada.

2. O PROBLEMA DIAGNÓSTICO

Segundo Cordier (2004) “*O objetivo do diagnóstico é identificar as causas primárias ...de um conjunto de sintomas observáveis...dada a importância desse problema para os sistemas críticos, uma ampla gama de abordagens tem sido desenvolvidas.*”

Muitas dessas abordagens enveredam pela cartilha puramente lógica, outras se utilizam de ferramentas estatísticas como a teoria da estimação e a teoria da decisão. De fato, existem duas grandes correntes que pesquisam teorias de diagnósticos de falhas: a comunidade DX (Diagnosis Community), fundamenta suas soluções dentro do campo da Ciência da Computação e da Inteligência Artificial (IA), tendo fortes ligações com NASA, e a comunidade de detecção e isolamento de falha (Fault Detection Isolation - FDI), que baseia suas soluções nas disciplinas de Engenharia de Controle e de Decisão Estatística (Cordier *et al*, 2004). Neste trabalho adotam-se ambas as abordagens, convenientemente.

Um Sistema de Engenharia, tal qual um avião, pode se apresentar em duas situações cruciais do ponto de vista de segurança, confiabilidade e qualidade: com a presença ou não de falhas. Esta é uma primeira visão para a construção do modelo aqui apresentado. Como uma primeira idéia para o conceito de falha, considera-se a mesma uma anormalidade no funcionamento do sistema, uma incapacidade do mesmo de executar o conjunto de funções ao qual se objetiva. Do desmembramento desse fato, verifica-se que um Sistema de Engenharia apresenta três estados possíveis: *Normal* (sem falhas), *Degradado* (falhas parciais ou em uma parcela de suas funções) e *Inoperante* (totalmente falho).

A inter-relação entre estes três estados é descrita na Figura 1.

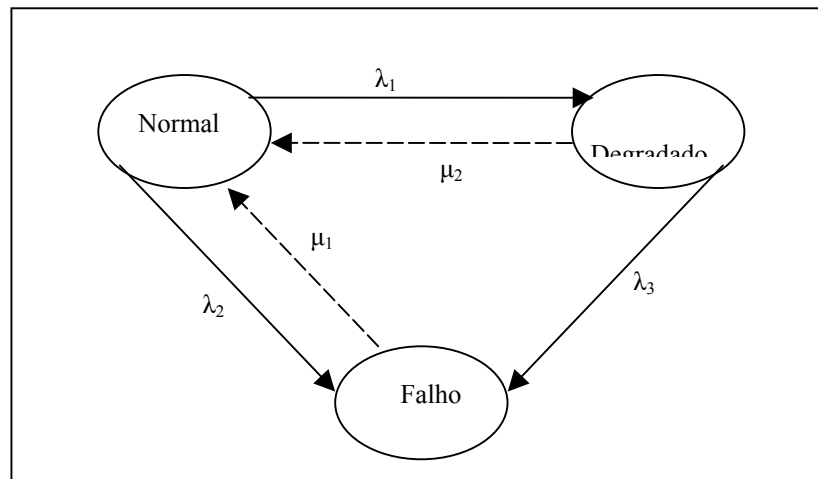


Figura 1: Diagrama ilustrando a inter-relação entre os três estados possíveis de um Sistema de Engenharia a ponto de vista do estudo de diagnóstico de falhas. Os valores $\lambda_1, \lambda_2, \lambda_3$ são as taxas de falhas que levam a uma situação de anormalidade. Já μ_1 e μ_2 são as taxas de correção.

A componente μ_i pode ser calculada pela expressão:

$$\mu_i = \frac{\Delta C}{\Delta T^M} \quad (1)$$

Sendo ΔC : Número de falhas corrigidas pelas ações de manutenção,
 ΔT^M Intervalo de Tempo gasto na manutenção ou do Sistema de Engenharia falho. Este tempo inclui as atividades de inspeções, cheques, serviços e reparos.

Um Sistema de Diagnóstico Automático (SDA) é uma ferramenta que implementa um processo de diagnóstico que tem como objetivo maximizar a taxa μ_i de maneira mais automatizada possível, ou seja, de forma a minimizar a intervenção humana. Definido esses termos, o papel de uma aplicação SDA no contexto da aplicação aeronáutica será analisado.

Do ponto de vista do diagnóstico de falhas, uma aeronave pode estar em dois estados principais em relação à sua utilização: operacional ou em manutenção. Um SDA agrega subsídios para a garantia da aeronavegabilidade da mesma. Apesar da definição não especificar, a utilização do SDA é assumida quando do momento da manutenção, vistorias ou inspeções, sejam elas preventivas ou não, anuais ou não, conforme o definido na IAC 3120-0278, pois, segundo Da Costa (2004): “*A Manutenção Aeronáutica é uma atividade que produz grande número de erros...Mesmo com... os métodos de segurança e Sistemas de Gerenciamento de Qualidade sendo arduamente estudados e implementados, o risco em manutenção nunca pode ser inteiramente eliminado...*”

Cabe esclarecer que um SDA não se restringe a ser um Manual de Manutenção em algum formato eletrônico. Ele pode sim fazer uso dos Métodos contidos no Manual como informação estruturada, porém tal informação compõe tão somente a base de conhecimento do SDA.

O processo de diagnóstico deve ter por características ser *eficiente e eficaz*.

Define-se o tempo gasto pelo SDA pela expressão:

$$\Delta T^D = \Delta T^M - \Delta T^C \quad (2)$$

Sendo ΔT^D : Tempo para o SDA para realizar o processo de diagnóstico de falha.

ΔT^C : Tempo efetivamente gasto para corrigir as falhas.

A eficiência do SDA se traduz em quanto o Sistema maximiza o índice de rendimento:

$$I = \frac{\Delta D}{\Delta T^D} \quad (3)$$

Sendo o termo D o conjunto dos Diagnósticos corretos fornecidos pelo SDA, ou seja, os casos onde não ocorre falso alarme ou perda. Uma situação de perda se constitui em casos onde o SDA deveria detectar uma falha e não o fez. O falso alarme corresponde à indicação de uma falha pelo SDA que não é observada realmente (Aguiar *et al*, 2001).

A diferença entre a quantidade de diagnósticos corretos e incorretos constitui-se na medida de eficácia do SDA, e pode ser expressa por:

$$E = \frac{\Delta D}{\Delta F} \quad (4)$$

Sendo ΔF o total de diagnósticos incorretos, seja por falso alarme ou por perdas.

Uma primeira abordagem para se tratar a questão do diagnóstico de falhas em Sistemas de Engenharia seria estabelecer uma relação imediata entre causa e efeito para todas as situações de falha passíveis de ocorrer no sistema em análise. Tal *tabela* seria elaborada de forma exaustiva para todas as situações experimentadas (informações empíricas) ou para cenários levantados *a priori* (através do uso de árvores de falha, por exemplo) e teria o formato lógico semelhante ao definido por Goldbarg (Goldbarg, Luna, 2000).

Tal cenário leva a alguns questionamentos: com o objeto de estudo é enxergado e como ele se comporta para que se possa levantar o conjunto completo de todas as relações de causa e efeito no que tange à situações de falha? Existe uma maneira eficiente de estabelecer essas relações, bem como verificar em qual caso (ou possivelmente casos) uma ocorrência se encaixa? Qual a plástica dessas relações de causa e efeito?

A maioria das teorias de diagnóstico de falhas das duas correntes atuais trabalha no modelamento do diagnóstico *per se* ou no modelamento dos eventos que levam o Sistema de Engenharia ao estado de falha ou degradação. Neste trabalho assumiu-se que, para se trabalhar de forma a tornar essas questões tratáveis satisfatoriamente, deve-se ter, como ponto de partida, a modelagem do objeto de estudo de forma orientada para possibilitar que os DAS's cumpram seus objetivos. Para tanto, lança-se mão do modelo de Sistemas Complexos Diagnosticáveis.

2.1. Sistemas Complexos Diagnosticáveis

Observa-se que muitas aplicações que objetivam diagnosticar Sistemas de Engenharia são desenvolvidas cada vez mais frequentemente, seja com uma metodologia bem definida, seja de forma mais empírica. Porém, tais aplicações têm a desvantagem de serem específicas aos objetos que se propõem a diagnosticar (Fijany, 2002). Surge portanto a questão: seria possível

pensar em um modelo substitutivo para sistemas diagnosticáveis que abarcasse uma vasta gama de Sistemas de Engenharia aparentemente heterogêneos entre si de modo que o processo de diagnóstico acompanhasse essa generalização? Se a resposta for sim, então se tem como construir SDA's que se adequem, senão a todos, pelo menos a um grande número de situações heterogêneas e, assim, construído um modelo que possibilite a criação de um Sistema de Diagnóstico Automático e Genérico, um SDAG.

O conceito de Sistema Complexo Diagnosticável surge portanto como ponto central para o estudo da engenharia diagnóstica. Segundo Storey (1996): “*Sistemas complexos são mais difíceis de serem projetados, portanto, mais susceptíveis a conter erros de projeto. Também são mais difíceis de testar, com maior chance, portanto, de conter erros não detectados. São mais vulneráveis a falhas humanas na instalação ou uso.*”

A base teórica dos Sistemas Complexos Diagnosticáveis (SCD) tem origem na Teoria Geral dos Sistemas desenvolvida por Ludwig von Bertalanffy (Bertalanffy,1969) e na teoria da Complexidade Computacional. Se for possível chegar-se a um *denominador comum* formal em relação a todos os Sistemas de Engenharia passíveis de serem diagnosticados, então os SDAG podem ser desenvolvidos e não estarão presos a uma determinada ATA ou modelo de aeronave em particular. Esta busca da generalização é a raiz do trabalho de Bertalanffy, apesar de seu trabalho inicial ter fortes influências da Biologia.

O termo *complexidade* vem do latim, *complexus*, que significa *entrelaçado*. Embora haja muitas abordagens para definir o que é um Sistema Complexo, seja ela do ponto de vista da Física, Economia ou Psicologia, aqui é interessante apenas o conceito de *Sistemas Complexos Diagnosticáveis*, ou seja, o termo complexidade será tratado dentro do escopo dos problemas de diagnósticos de falhas. Para tanto, assume-se os quatro postulados abaixo que serão a base da modelagem aqui apresentada:

Postulado 0: O SCD é um Sistema da forma como o *IEEE Electronics Terms* define a palavra: “uma combinação de componentes (elementos) que agem juntos para realizar uma função ao qual não seria possível de ser realizada pelas partes (elementos) individualmente.” Além disso, o SCD é um ente entrópico e não conservativo.

Postulado 1: O SCD deve ser composto de um conjunto com mais de um elemento. Deve ser possível criar mais de um conjunto onde os elementos diferem quanto a sua natureza de um para outro. Cada um dos elementos que compõem o SCD deve ter pelo menos uma interligação com outro elemento do Sistema que não seja ele mesmo. Tais interligações compõem a estrutura do Sistema de tal forma que a mesma seja estável (Heylighen,1988). Entende-se por estabilidade a propriedade da estrutura permanecer invariante no tempo, completamente definida e organizada. Estas ligações devem tornar o SCD sinérgico e simbiótico, interna e externamente (Goldbarg, Luna, 2000).

Postulado 2: Deve haver um conjunto mínimo de elementos do SCD onde seja possível fornecer um conjunto mínimo não vazio de observações de suas variáveis características. Entende-se por variáveis características as medições de um subconjunto não vazio do total das dimensões que definem um elemento que compõem o SCD, sejam elas estáticas ou dinâmicas.

Postulado 3: O emprego de métodos reducionistas e abstrações para a análise do SCD tem um

limite físico. Em determinado momento não se poderá mais subdividir partes do Sistema em subelementos menores.

Agora pode-se, capitaneados por Bertalanffy, definir um Sistema Complexo Diagnosticável R.

Definição 1: Um Sistema Complexo Diagnosticável R é definido como uma quádrupla:

$$R \in \mathfrak{S} \Leftrightarrow R = (S, E, L, G) \quad (5)$$

Sendo \mathfrak{S} o Conjunto dos Sistemas Diagnosticáveis.

$$\mathfrak{S} = (R_1, R_2, \dots, R_n) \quad (6)$$

S: Conjunto dos Subsistemas de R. $S \in R$ é a *hierarquia* de R, de forma que:

$$S = (K_1, K_2, \dots, K_n) \text{ com } S \subset \mathfrak{S} \text{ e } K_i \neq R \quad (7)$$

Ao nível de hierarquia de R damos o nome de *complexidade* de R.

E: é o conjunto dos componentes do Sistema Diagnosticável de forma que:

$$E = (C_1, C_2, \dots, C_n) \text{ com } E \subset \mathfrak{S} \quad (8)$$

\mathfrak{R} : é o conjunto dos componente de \mathfrak{R} e é descrito pelo par ordenado:

$$C = (V^C, H^C) \quad (9)$$

Sendo V o conjunto de variáveis características do componente C de tal forma que:

$$V^C = (v^C_1, v^C_2, \dots, v^C_n) \text{ com } v^C_i \in \mathfrak{R} \text{ (conjunto dos Reais)} \quad (10)$$

H: é o vetor de serviços de C de tal forma que:

$$H^C = (h^C_1, h^C_2, \dots, h^C_n) \text{ onde } h : \mathfrak{R}^m \rightarrow \mathfrak{R}^n \text{ para } v \in V \quad (11)$$

Um serviço h é uma transformação de um subconjunto de V, onde cada elemento v é alterado em v' seja h linear ou não. Para a nossa definição de R, basta que os elementos de V sejam descritivos e não controláveis (Goldbarg, Luna, 2000).

Ocasionalmente, o conjunto V pode ser vazio, porém, deve existir pelo menos um elemento no conjunto que se denomina E em que tal fato não ocorra. Cabe salientar que as variáveis características pertinentes ao diagnóstico são definidas no domínio do usuário de manutenção ou monitoração técnica, tal seleção pode se resumir a um subconjunto de V para um determinado C ou consistir no próprio conjunto V. De um modo geral, as variáveis escolhidas devem se consistir em todos os dados representativos do bom funcionamento ou não do componente.

Continuando a descrição do enunciando de R:

L: é chamado de *conjunto estrutura* onde:

$$L = (l_1, l_2, \dots, l_m) \text{ com } l_p = (C_m^{iK}, C_n^{jK'}) ; i < j ; C \in E ; p \leq |S| \times |E| ; K, K' \subset S \quad (12)$$

G: é denominado conjunto funcionalidade de R quando:

$$G = (G_I, G_E) \text{ é um mapeamento } V^{iK}_m \rightarrow V^{jK'}_n \text{ pertencentes a } C_m^{iK} \text{ e } C_n^{jK'} \text{ respectivamente.} \quad (13)$$

Sendo G_I o conjunto das Funcionalidades Internas.

G_E o conjunto das Funcionalidades Externas.

Definidas por $G_I : L \rightarrow H^C$ com $l_p \neq (C_m^{i^0}, C_n^{j^{K'}})$ e $l_p \neq (C_m^{i^K}, C_n^{j^0})$

$$G_E : L \rightarrow H^C \text{ com } l_p = (C_m^{i^0}, C_n^{j^{K'}}) \text{ ou } l_p = (C_m^{i^K}, C_n^{j^0}) \quad (14)$$

Com $C_m^{i^0}$ representando uma entrada do Sistema R

$C_n^{j^0}$ representando uma saída do Sistema R

2.2. Conseqüências do modelo : O enunciado do Problema Diagnóstico

Definição 2: Um *Defeito* é uma transformação $C_i \rightarrow C_i'$, de modo que para todos os elementos de L que contenham C_i , tem-se uma alteração no conjunto G. Portanto, um defeito é uma alteração estrutural que modifica ou incapacita a execução de um subconjunto de G.

Definição 3: Uma alteração $G \rightarrow G'$ em um determinado instante t constitui uma *Falha*.

Definição 4: Uma *observação* $O^C_{(tipo)}$ é um conjunto gerado em um determinado instante t a partir dos conjuntos V^C e H^C para um componente C com $O^C_{(tipo)} \subseteq V^C \cup H^C$ e $C \in E$ para um dado R. Onde *tipo* pode ser externo ou interno dependendo se envolve ou não componentes com entradas ou saídas do Sistema.

Definição 5: Um *histórico* Ω^C é o conjunto de todas as observações $O^C_{(tipo)}$ geradas em um intervalo de tempo Δt .

Definição 6: Uma *mensuração* é uma função $M : \Omega^C \rightarrow \mathfrak{R}^N$

Definição 7: Restrição Operacional Direta são os intervalos para cada valor em $V^C \cup H^C$ para os quais não se verifica a ocorrência de um ou mais defeitos no componente C. Dessa forma, uma restrição será um conjunto P^C dos valores $P^C = (P_{V_1}^C, P_{V_2}^C, \dots, P_{V_n}^C, \dots, P_{H_1}^C, \dots, P_{H_n}^C)$ onde $P_{V_i}^C \subset \mathfrak{R}$ e $P_{H_j}^C \subset \mathfrak{R}^m \rightarrow \mathfrak{R}^n$ para os quais não se verifica $G \rightarrow G'$.

Definição 8: Restrição Operacional Indireta são os intervalos de uma mensuração para o qual não se verifica a ocorrência de um ou mais defeitos no componente C. Dessa forma, uma Restrição Operacional Indireta será um conjunto $Q^C \subset \Omega^C \rightarrow \mathfrak{R}^N$.

Definição 9: Um Sintoma Direto é uma máquina de Turing Γ que decide se $O^C_{(tipo)} \notin P^C$ para um determinado componente. Caso a observação não seja uma restrição operacional é dito que foi verificado um sintoma.

Definição 10: Um Sintoma Indireto é uma máquina de Turing Λ que decide se o conjunto de entrada $O^C \notin Q^C$ para um determinado componente.

Definição 11: Uma Síndrome é um conjunto Σ de sintomas diretos e indiretos verificados em um mesmo R. Para um mesmo componente pode-se ter vários sintomas.

Definição 12: Ao conjunto de Síndromes distintas para um dado componente, dá-se o nome

D_i de *Diagnósticos de C* em R . Um diagnóstico é, portanto, o conjunto de Sintomas que definem um mesmo defeito em C .

Definição 13: O problema diagnóstico constitui portanto o processo de se identificar D_i a partir do conjunto M e Ω^C obedecendo os princípios de eficiência e eficácia.

O Diagnóstico pode ser estabelecido por um processo definido pelas seguintes etapas: *Aquisição, Tratamento e Interpretação*. Pode parecer que estes elementos são comuns a vários processos outros que não o diagnóstico. Porém, será observado que a decomposição do processo de diagnóstico nestas etapas é de suma importância para definir-se as classes de diagnósticos bem como o seu alcance.

3. ESTUDO DE CASO: APLICAÇÃO DE RNA's NO DIAGNÓSTICO PREDITIVO DE UM ATUADOR SOB PROCESSO DE DEGRADAÇÃO FUNCIONAL

Neste tópico, será analisada a viabilidade do modelo proposto. Para tanto, será utilizado *Diagnóstico Preditivo Auxiliado por Sensores*. Destacam-se os elementos do modelo para o tratamento do Diagnóstico:

- *Componente a ser Diagnosticado (C):* Atuador Genérico Sensoriado
- *Observação ($O^C_{(interna)}$):* Linha específica do arquivo de log (registros) dos sensores
- *Histórico (Ω^C):* Arquivo de log dos sensores
- *Mensuração (M):* Rede Neural Artificial tipo *Multi Layer Perceptron* (MLP) com algoritmo *Backpropagation*
- *Sintoma Indireto:* $M > Limite$

Dado um componente C a ser diagnosticado preditivamente e que seja passível de sofrer degradação, apresentando um conjunto de registros (*log*) históricos sobre seu comportamento e uma função representativa de sua síndrome, gerada a partir desse log, uma Rede Neural Artificial, tipo MLP, treinada com o algoritmo Backpropagation, pode ser empregada para realizar o objetivo pretendido: diagnóstico preditivo de seus estados de degradação futuros.

Como estudo de caso aqui analisado, tem-se um atuador C , passível de sofrer degradação de suas funções, que apresenta o comportamento temporal, extraído de seu arquivo de log, dado abaixo:

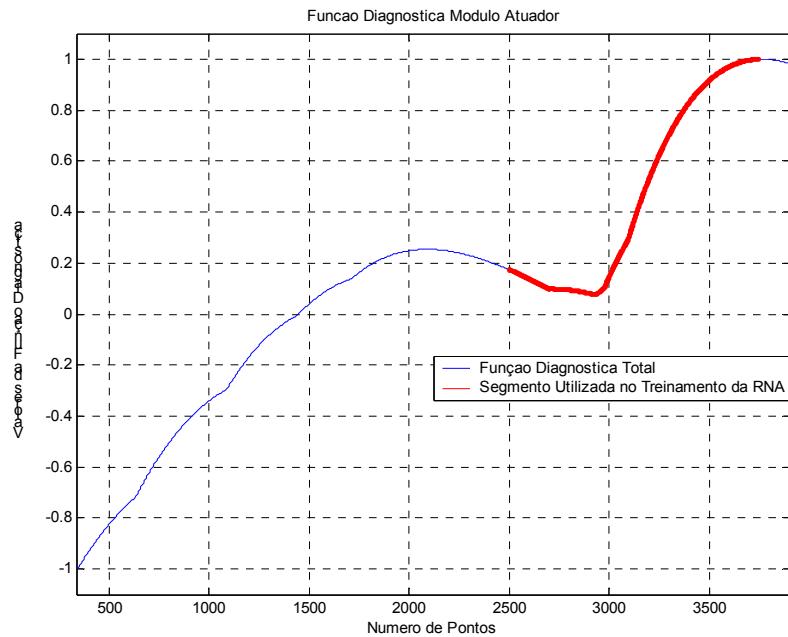


Figura 2: Gráfico da função temporal do atuador estudado, observando-se no eixo x, os números de pontos (registros de atividades) e em y o valor acumulado de seus eventos de erros de operação extraídos de seu log.

A função acima é obtida tendo-se como base os registros de erros de operação do atuador, encontrados em seu log, acumulados no tempo em uma janela exponencial, seguindo as equações abaixo:

$$y_i = \alpha \cdot y_{(i-1)} + (1 - \alpha) \cdot x_i \quad (15)$$

$$y'_i = \beta \cdot y'_{(i-1)} + (1 - \beta) \cdot y'_i \quad (16)$$

Sendo: x_i a ocorrência ou não do evento de erro de atuação de C, α e β índices de memória e suavização das funções acima descritas.

Analisando-se a função do gráfico acima, originada pela Equação 16, observa-se que seu comportamento evolui para um estado de degradação que, ultrapassado um Limite aceitável, deixa C inoperante. Admitindo-se que esse Limite seja de 85% do máximo de degradação possível (ponto 0.85), uma Rede Neural Artificial pode ser devidamente treinada para, antes que esse ponto seja atingido realmente, predir quando ele será atingido, podendo-se assim, antecipar sua manutenção, não ocorrendo indisponibilidade do equipamento devido a inoperação do mesmo.

Para tal análise, foi considerado o trecho observado a partir do ponto 2500 até o cume maior do gráfico, por volta de 3700 (em vermelho), que representa o estado de degradação máxima, como o comportamento de C que acarretará uma Falha intolerável ao seu desempenho. Esse trecho serviu como base para o treinamento e teste da RNA implementada.

O objetivo da RNA era de antecipar pontos do comportamento degradado do módulo C em estudo. Para isso, o conjunto de pontos acima referido foi amostrado (a cada 20 pontos) e dividido em *Conjunto de Treinamento (CT)* e *Conjunto de Teste (CTe)* da RNA. Ambos somados totalizaram 63 pontos. A amostragem foi necessária para que a Rede analisasse apenas o comportamento do sistema, sem sobrecarga de informações desnecessárias.

Dos 63 pontos utilizados para a Rede, 35 pontos foram utilizados como CT, que pode ser observado abaixo:

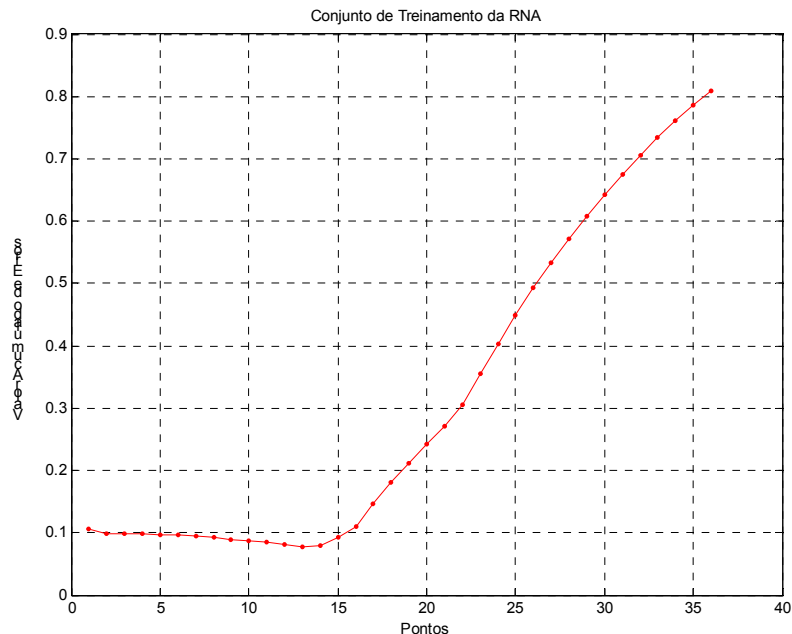


Figura 3: Conjunto de Treinamento da RNA

Esse CT foi preparado para ser analisado pela RNA de forma a possibilitar que a Rede desempenhasse um papel de preditora do comportamento de C. Assim, esse conjunto foi janelado a cada 5 operações (pontos) tendo como *target* (alvo) o sexto ponto (previsão de 1 estado futuro), com 1 passo de avanço.

Para que tal função preditora fosse alcançada, a RNA utilizada foi uma MLP contendo 3 neurônios na camada oculta, com função de ativação sigmoideal, e 1 neurônio na camada de saída, com função linear de ativação. Esta arquitetura mostrou-se a mais satisfatória e com menor erro médio quadrático durante seu treinamento, porém, outras combinações de números de neurônios, camadas e funções de ativações foram testadas e analisadas até chegar-se a esta definitivamente (Haykin, 2001).

Como algoritmo de treinamento foi utilizado o *Backpropagation* (ou Retropropagação do Erro) por mostrar-se eficaz na minimização do erro médio quadrático, ficando este em torno de 0.0001 (Kovács, 2002).

Como resultado, obteve-se a predição de 5 estados futuros, com erro máximo de 4,1% no último ponto, como pode ser observado na Figura 4.

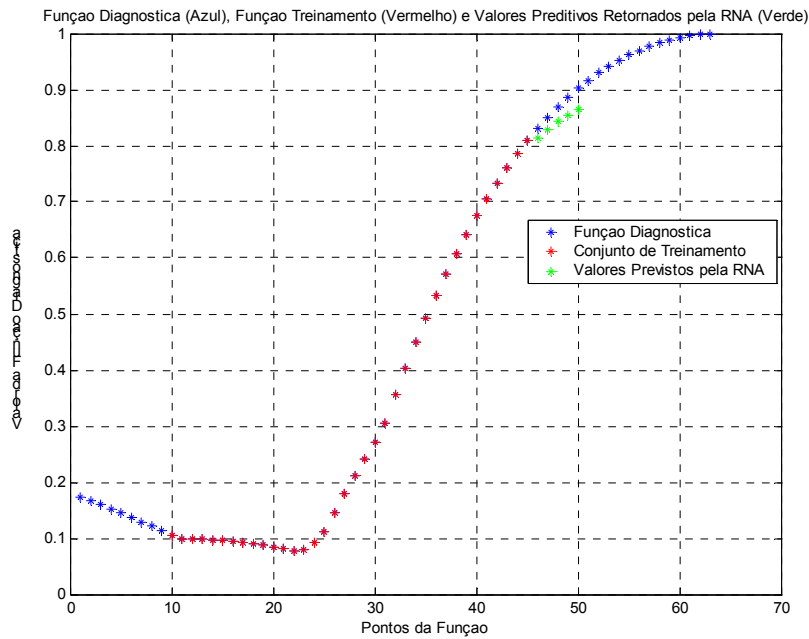


Figura 4: Resultado do Treinamento e Teste da RNA. Em vermelho encontram-se os pontos utilizados no treinamento da Rede, em Verde, os estados previstos pela RNA em seu Teste e em azul, os pontos reais da função do atuador degradado.

Mostrando os resultados da predição mais proximamente, observa-se:

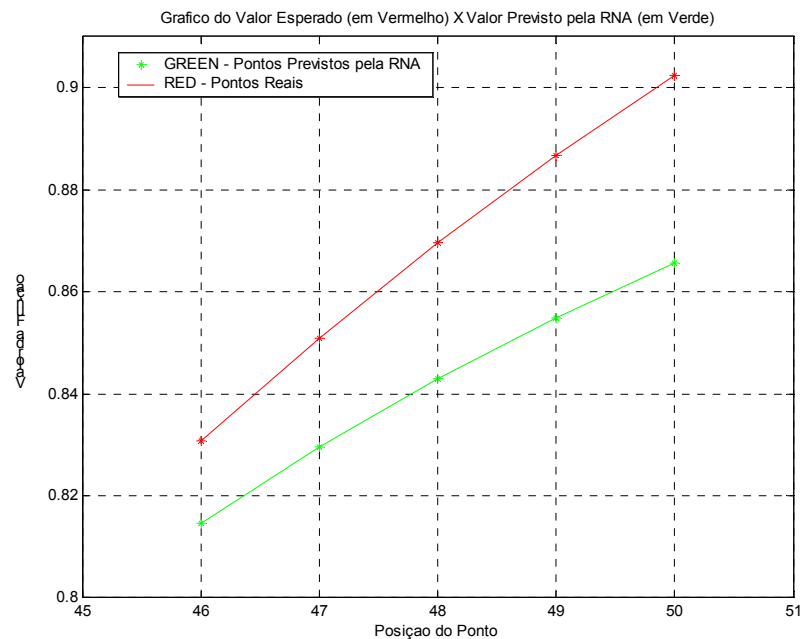


Figura 5: Zoom dos resultados obtidos nos testes da RNA preditora.

Os erros de aproximação para cada ponto, foram: 1,93%, 2,49%, 3,05%, 3,59% e 4,10%, respectivamente.

Considerando-se que os dados foram amostrados e fazendo-se o retorno para as operações registradas, podemos concluir que a RNA utilizada mostra-se satisfatória para prever 100

operações futuras do estado do atuador considerado. Com esses dados, uma manutenção preventiva pode ser devidamente agendada para que o Limite de degradação tolerável nunca seja ultrapassado.

Um dos alarmes referentes ao sistema de controle de vôo, ATA 27, Capítulo 27 da *Air Transportation Association*, sub-ATA 36, “Stall Protection System”, é a mensagem “*AOA Fail*” (*Angle of Attack Fail*), normalmente registrada no *CMC* (*Central Maintenance Computer*) de uma aeronave. A mensagem de erro “*AOA Fail*” encontra-se no *log* do *CMC* e pode ser originada por uma variedade de causas raiz entre as quais pela falha de um dos sensores *AOA* presentes na aeronave.

Considerando-se então, que a falha de um sensor *AOA* é uma causa raiz diagnosticável C , a partir do *log* histórico do *CMC* (O^C e \mathcal{O}^C), pode-se treinar uma MLP e, estabelecendo-se um *Limite* para o *Sintoma Indireto* ($M > Limite$), observa-se que as análises desenvolvidas para um Atuador Genérico Sensoriado, anteriormente demonstradas, podem ser aplicáveis aos sensores *AOA*, possibilitando assim, sua manutenção preventiva, evitando-se a parada da aeronave exclusivamente para se consertar um defeito dos sensores que se apresentaria, certamente, caso a manutenção preventiva, com conhecimentos dos estados futuros dos sensores, não tivesse ocorrido no tempo adequado.

4. CONCLUSÕES

O modelo proposto se adequou à situação experimental, mostrando ser possível aplicá-lo no diagnóstico de um módulo que se comportou como um SCD ao ser analisado: de maneira independente de qualquer pré-requisito que não fosse os elementos que compõem a definição do próprio SCD. Obteve-se também um resultado preditivo livre de qualquer detalhe particular de algum processo de manutenção ou de dados de confiabilidade nominais. A predição foi feita unicamente com ferramentas estatísticas e com os dados gerados e fornecidos pelo próprio SCD. O diagnóstico é um problema complexo, assim uma abordagem cognitiva na forma de Redes Neurais MLP para possibilitar o tratamento dessa complexidade, sem deixar de lado a importância dos processos estatísticos no pré-tratamento, foi aqui observada. Os passos seguintes serão focados na análise de alternativas para as topologias de Redes Neurais e na aplicação do modelo de SCD em outros Sistemas de Engenharia.

REFERÊNCIAS BIBLIOGRÁFICAS

- Aguiar, M. A., Kovacs, Z. L. Destro, R. C., Pelaez, J. R., Simões, M. G. (2001) Predictive Maintenance Oriented Neural Network System - PREMON In: IECON'01, 2001, Denver, Colorado. Anais do IECON'01.
- Aguiar, M. A. (2001) Diagnóstico de falhas em equipamentos usando técnicas de Redes Neurais Artificiais. Dissertação de Mestrado, Escola Politécnica da USP.
- Bertalanffy, L. Von (1969) General Theory of Systems. N. York, George Braziller.
- Cordier, M. O. Dague, P. Lévy, F. Montmain, J. Staroswiecki, Marcel. Travé-Massuyès, L. (2004) Conflicts Versus Analytical Redundancy Relations: A Comparative Analysis of the Model Based Diagnosis Approach From the Artificial Intelligence and Automatic Control Perspectives. IEEE Transactions on Systems, Man, and Cybernetics -Part B: Cybernetics, Vol. 34, No. 5, October.
- Da Costa, V. A. C. (2004) Manutenção Aeronáutica e Controle de Qualidade em Prol da Segurança de Vôo.
- Fijany, A. Vatan, F. Barrett, A. Mackey, R. (2002) New Approaches for Solving the Diagnosis Problem. IPN Progress Report, pag 42-149.
- Goldberg, M. C. Luna, H. P. L. (2000) Otimização Combinatória e Programação Linear, Modelos e

Algoritmos. Editora Campus.

Haykin, S. (2001) Redes Neurais: Princípios e Prática. 2ª Ed; Porto Alegre: Bookman.

Heylighen, F. (1988) Building a Science of Complexity. 1988 Annual Conference of the Cybernetic Society. London.

IAC 3120-0278 elaborado pelo DAC- Departamento de Aviação Civil.

Kovács, Z. L. (2002) Redes Neurais Artificiais: Fundamentos e Aplicações. 3ª Ed. São Paulo: Livraria de Física.

Storey, N. (1996) Safety-Critical Computer Systems. Addison-Wesley.

Reginaldo Inojosa da Silva Filho (reginaldo.filho@poli.usp.br)

Mariana Antonia Aguiar (mariana@lsi.usp.br)

Zsolt Lazslo Kovács (kovacs@lac.usp.br)

Departamento de Sistemas Eletrônicos, Escola Politécnica, Universidade de São Paulo

Avenida Prof. Luciano Gualberto, travessa 3 n° 380 - CEP - 05508-900 - São Paulo – SP, Brasil