

Detecção e Diagnóstico Preditivos de Falhas em Equipamentos de Automação Bancária Utilizando Redes de Sensores

M. A. Aguiar¹, R. I. Silva Filho², R. A. Furucho³, Z. L. Kovács⁴

¹Laboratório de Sistemas Integráveis (LSI) – NAPCC

^{2,4}Laboratório de Automação e Controle (LAC)

Escola Politécnica da Universidade de São Paulo – POLI/USP

³Centro Universitário das Faculdades Metropolitanas Unidas – UniFMU

* Autor Responsável: Mariana Antonia Aguiar, +55 11 3091-5671, mariana@lsi.usp.br

ABSTRACT

This paper presents an introduction to the concepts of Systems for Fault Detection and Diagnosis and its automation applications to ATM maintenance. The basics of the diagnosis 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 MMD sensed of ATM is also developed.

KEYWORDS: detection, diagnosis, prediction, sensor, Artificial Neural Network.

1. Introdução

Com o avanço da ciência e tecnologia, as aplicações científicas e de engenharia no setor de automação bancária se tornam cada vez mais necessárias. Aliado a esse fato, tem-se que a alta disponibilidade de equipamentos, cada vez mais exigida pelo aumento da demanda sobre os serviços fornecidos pelo setor bancário, torna-se um diferencial competitivo para as empresas do referido setor.

Desta forma, o diagnóstico de falhas é um tema de relevância cada vez maior, não só do ponto de vista acadêmico, mas também econômico, na medida em que os responsáveis pela área se conscientizam de que as ferramentas de diagnóstico se tornarão uma parte cada vez mais importante a serem incorporadas aos seus produtos.

Observa-se, porém, que existe a necessidade não só de se criar métodos e ferramentas para tratar essas questões, mas garantir, de maneira formal, sua eficiência e correção.

Este artigo tem como objetivo discutir e implementar uma solução que busca ser ótima e genérica para o problema de detecção e diagnóstico preditivos de falhas, ou seja, uma ferramenta independente de uma aplicação específica.

2. O Problema Diagnóstico

Segundo Cordier [1], “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.”

Um Sistema de Engenharia, tal qual um equipamento de automação bancária, como o MMD, Multimedia Machine Dispenser, ou Cash Dispenser, que fica localizado dentro do ATM, Automatic Teller Machine, ou equipamento de auto-atendimento bancário, pode apresentar duas situações cruciais do ponto de vista da segurança, confiabilidade e qualidade: com ou sem falhas.

Esta é uma primeira visão para a construção do modelo aqui apresentado. Como primeira idéia do conceito falha tem-se que ela, simplesmente, é uma anormalidade no funcionamento de um 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 que um Sistema de Engenharia do ponto de vista do estudo do diagnóstico de falhas. Os valores $\lambda_1, \lambda_2, \lambda_3$ são as taxas de falhas de 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 seguinte expressão:

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

Onde ΔC : Número de falhas corrigidas pelas ações de manutenção

ΔT^M : Intervalo de Tempo gasto na manutenção do Sistema de Engenharia fãlho.

Um Sistema Automático de Detecção e Diagnóstico (SADD) 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 otimizar e minimizar a intervenção humana. Tal processo de diagnóstico deve ter por característica ser *eficiente* e *eficaz*.

Se definir o tempo gasto pelo SADD pela expressão:

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

Onde ΔT^D : Tempo para o SADD para realizar o processo de diagnóstico de falha.

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

A eficiência do SADD se traduz em quanto o Sistema maximiza a função rendimento:

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

Onde o termo D é o conjunto dos Diagnósticos corretos fornecidos pelo SADD, ou seja, os casos onde não ocorreram casos de falso alarme ou perda. A diferença entre a quantidade de diagnósticos corretos e incorretos constitui-se na medida de eficácia do SADD, e pode ser expresso por:

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

Onde ΔF é 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 ocorrerem 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 segundo Goldbarg [2].

2.1. Descrição do Sistema MMD

Um MMD, ou Multimedia Machine Dispenser, é um

dispositivo eletrônico/mecânico complexo, composto por três grandes módulos operacionais: *Dispensador*, *Presenter* e *Placa Controladora* [3] [4].




Figura 2. Esquema de um MMD tipo "front-load"

O *Dispensador* é responsável pela contagem das cédulas solicitadas pelo usuário, composto principalmente por:

- *Alimentador*: canal físico onde se encaixa o cassete, chegando ao máximo no número de quatro no tipo de equipamento utilizado nesta pesquisa;
- *Correias*: responsáveis pelo transporte das cédulas até o presenter;
- *Cassetes*: onde são armazenadas as cédulas a serem entregues, chegando no máximo a um número de quatro também no equipamento aqui utilizado, e combinando-se logicamente com os Alimentadores;
- *Sensores*: responsáveis pela contagem de cédulas que saem dos cassetes, apresentando um sensor por alimentador.

O *Presenter*, como o próprio nome já diz, apresenta as cédulas contadas para o usuário que solicitou a operação de saque, apresentando os sub-componentes:

- *Cam*: peça mecânica controlada eletronicamente, responsável pelas funções de empilhamento, transporte e entrega das cédulas contadas;
- *Push Plate*: definido como um "carrinho" que auxilia no transporte das cédulas empilhadas até o local de saída;
- *Shutter*: dispositivo que se assemelha a uma porta, que quando acionado, libera a saída das cédulas para o usuário;
- *Sensores*: há um sensor responsável pela detecção de passagem da cédula pelo presenter e outro sensor que se encarrega de verificar se as cédulas foram entregues ao usuário;
- *Correias*: juntamente com o Push Plate e o Cam são responsáveis pelo transporte das notas até o

usuário.

A *Placa Controladora* é uma placa de circuito impresso que tem a função de controlar todo o funcionamento do MMD. Ela está conectada a um microcomputador presente dentro da ATM responsável pelo controle supervisão da mesma.

Como observação, pode ser mencionada a presença de um cassete de rejeição que fica localizado entre o Dispensador e o Presenter. É nesta caixa de rejeição que as cédulas que apresentaram algum problema durante a contagem, ou mesmo todo o montante da contagem ocasionalmente errada, tem como destino.

2.2. Conseqüências do modelo: O enunciado do Problema Diagnóstico

Abaixo, apresentam-se as definições utilizadas neste trabalho para o desenvolvimento da solução proposta [5].

Definição 1: Um *Defeito*, D , é uma alteração estrutural que modifica ou incapacita a execução de um subconjunto das funcionalidades do Sistema Complexo Diagnosticável em questão, aqui chamado de R .

Definição 2: Uma alteração $G \rightarrow G'$ em um determinado instante t constitui uma *Falha*.

Definição 3: Uma *observação* $O^C_{(tipo)}$ é um conjunto gerado em um determinado instante t onde *tipo* pode ser externo ou interno dependendo se envolve ou não componentes com entradas ou saídas do Sistema.

Definição 4: Um *histórico* Ω^C é o conjunto de todas as observações $O^C_{(tipo)}$ geradas em um intervalo de tempo Δt .

Definição 5: Uma *mensuração* é uma função $M: \Omega^C \rightarrow \mathfrak{R}^N$

Definição 6: 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 7: Ao conjunto de Síndromes distintas para um dado componente, dá-se o nome de *Diagnósticos de C* em R . Um diagnóstico é, portanto, o conjunto de Sintomas que definem um mesmo defeito em C .

Definição 8: O problema diagnóstico constitui, portanto, no *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 do diagnóstico nestas etapas é de suma importância para se definir as

classes de diagnósticos bem como o seu alcance.

2.3. Classes de Diagnóstico

2.3.1. Quanto à aquisição e tratamento: Diagnóstico por Troubleshooting e Diagnóstico Auxiliado por Sensores

A etapa da aquisição engloba a obtenção dos dados descritos nas definições 3, 4 e 5, já o tratamento trabalha com as outras definições. O foco, portanto, recai em como a Síndrome é verificada e registrada e como, a partir desta, o defeito é corrigido.

Segundo Sochorov [6] o diagnóstico por sequência de teste ou Troubleshooting constitui na construção por parte da equipe de manutenção da sequência de perguntas *in loco* e execução de ações que definem a Síndrome e corrigem o defeito presente. O troubleshooting parte do pressuposto de que é necessária a intervenção humana através de testes (perguntas) para se isolar a Síndrome, porém tendo como fator limitante o custo associado às ações e perguntas. Portanto, uma sessão de troubleshooting deve isolar o defeito de forma *a minimizar o custo*.

Já no Diagnóstico auxiliado por sensores, as etapas definidas acima têm sua execução realizada ou auxiliada por uma Rede de Sensores presentes nos componentes e que realizam as observações e, dependendo da *inteligência* da Rede, o processamento dos Sintomas. Esta abordagem tem a vantagem de propiciar um pré-tratamento dos dados, permitindo, quando do momento da manutenção, que um grande volume de processamento já tenha sido realizado.

2.3.2. Quanto à Interpretação: Diagnóstico Preditivo e Diagnóstico Corretivo

No Diagnóstico preditivo, a verificação ou não do diagnóstico para um determinado componente é estabelecida deslocando-se o instante de tempo a ser analisado para um intervalo futuro desejado mediante uma função de predição a partir do histórico Ω^C representativo. Já no Diagnóstico corretivo, o instante de tempo que determina o processo de decisão é o instante presente, são os componentes falhos no momento que são detectados.

3. Aplicação de RNA's para Diagnóstico Preditivo no Sistema Sensoriado do MMD

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 e tipo Radial Basis Function.

Sintoma Indireto: $M > \text{Limite}$.

Dado um componente C a ser diagnóstico preditivamente 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 pode ser empregada para realizar o objetivo pretendido: diagnóstico preditivo de seus estados de degradação futuros.

Como estudo de caso aqui analisado, tem-se o MMD, passível de sofrer degradação de suas funcionalidades, que apresenta o comportamento temporal, extraído de seu arquivo de log, dado na Figura 3.

A função esboçada é obtida tendo-se como base os registros de erros de operação do Contador (C), que é o módulo de contagem de cédulas do MMD, encontrados em seu log, acumulados no tempo em uma janela exponencial, seguindo as equações abaixo:

$$y_i = \alpha \cdot y_{(i-1)} + (1 - \alpha) \cdot x_i \quad (5)$$

$$y'_i = \beta \cdot y'_{(i-1)} + (1 - \beta) \cdot y^2_i \quad (6)$$

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.

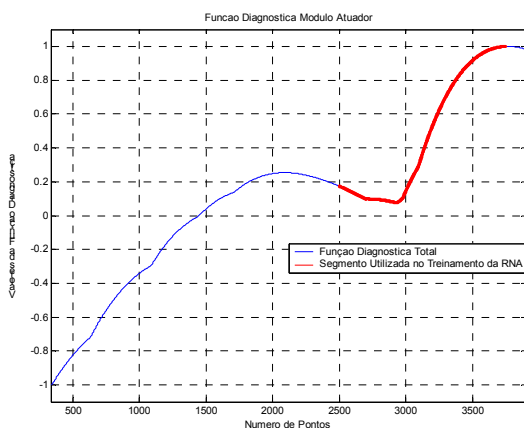


Figura 3: Gráfico da função temporal do MMD estudado, observando-se no eixo x, os números de pontos (registros de atividades) e em y o valor acumulado de seus eventos de erros de operação extraídos de seu log.

Analisando-se a função do gráfico acima, originada pela Equação (6), 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, prediga quando ele será atingido, podendo-se assim, antecipar sua manutenção, não ocorrendo indisponibilidade do equipamento devido a inoperabilidade 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 das RNA's implementadas.

O objetivo das RNA's 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)* das RNA's. 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 as Redes, 35 pontos foram utilizados como CT, que pode ser observado abaixo:

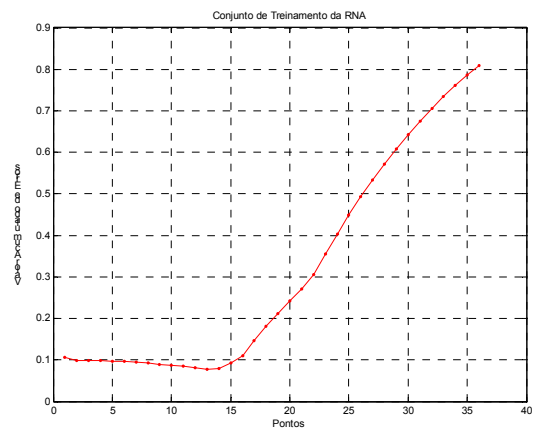


Figura 4: Conjunto de Treinamento das RNA's

Esse CT foi preparado para ser analisado pelas RNA's de forma a possibilitar que as Redes desempenhassem um papel de preditoras 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, foram utilizadas as Redes com as seguintes arquiteturas:

a) RNA tipo MLP com algoritmo de treinamento Backpropagation

A RNA tipo MLP continha 4 neurônios na camada oculta, com função de ativação sigmoideal, e 1 neurônio na camada de saída, com função linear de ativação [7]. 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.

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.

Como resultado, obteve-se a predição de 8 estados futuros, com erro máximo de 5,43% no último ponto, como pode ser observado na Figura 5.

Os erros de aproximação para cada ponto, foram: 1,93%, 2,49%, 3,05%, 3,59%, 4,10%, 4,58%, 5,02% e 5,43%, 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 razoável para prever 160 operações futuras do estado do atuador considerado.

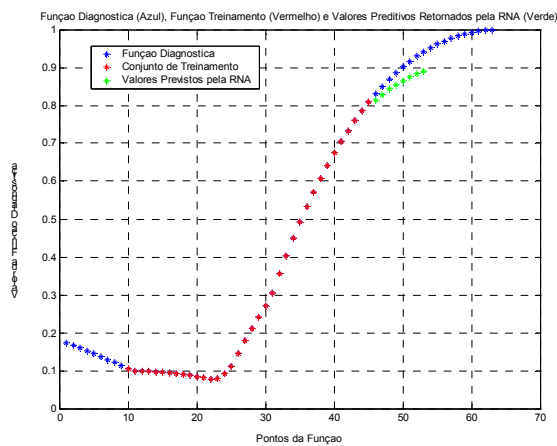


Figura 5: Resultado do Treinamento e Teste da RNA. Em vermelho encontram-se os pontos utilizados no treinamento da Rede, em Verde, os estados previstos pela RNA em seu Teste e em azul, os pontos reais da função do atuador degradado.

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

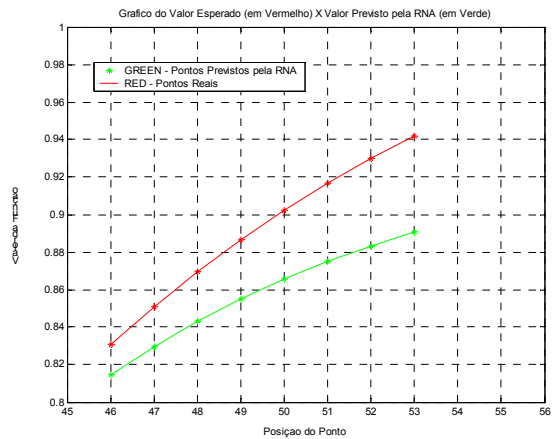


Figura 6: Zoom dos resultados obtidos nos testes da RNA MLP preditora. Em vermelho: pontos reais, em Verde: pontos fornecidos pela Rede.

b) RNA tipo Radial Basis Function - RBF

Considerando-se o mesmo conjunto de treinamento utilizado na Rede MLP, a RNA tipo RBF utilizada continha 12 neurônios na camada oculta, com função de ativação gaussiana, e 1 neurônio na camada de saída, com função linear de ativação, sendo a arquitetura mais satisfatória para este problema dentre as pesquisadas [8].

O erro médio quadrático foi também de 0.0001 e constante de dispersão com valor 1 padrão.

Como resultado, obteve-se a predição de 8 estados futuros, com erro máximo de 0,29% no último ponto, como pode ser observado na Figura 7.

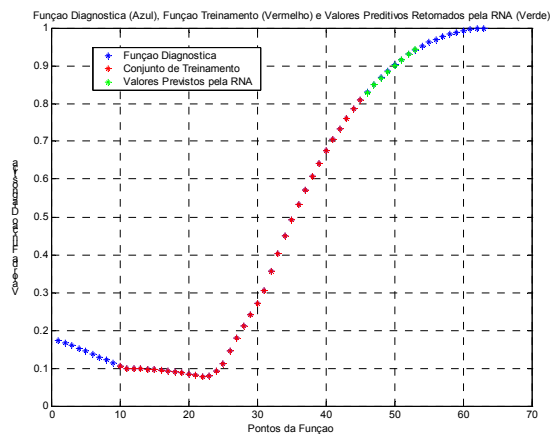


Figura 7: Resultado do Treinamento e Teste da RNA RBF. Em vermelho encontram-se os pontos utilizados no treinamento da Rede, em Verde, os estados previstos pela RNA em seu Teste e em azul, os pontos reais da função do atuador degradado.

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

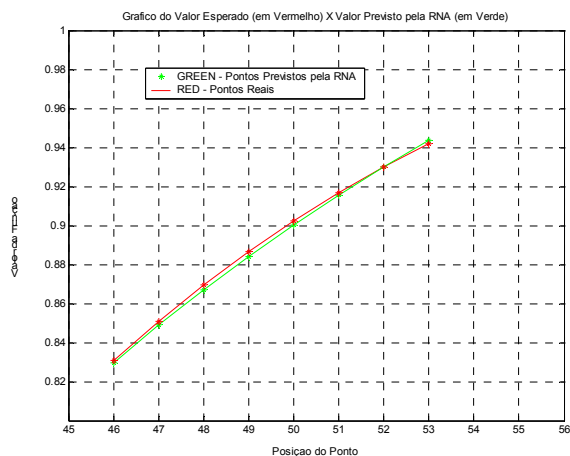


Figura 8: Zoom dos resultados obtidos nos testes da RNA RBF preditora. Em vermelho: pontos reais, em Verde: pontos fornecidos pela Rede.

Os erros de aproximação para cada ponto, foram: 0,12%, 0,20%, 0,27%, 0,29%, 0,26%, 0,17%, 0,01% e -0,21%, respectivamente.

Considerando-se que os dados foram amostrados nas exatas condições descritas na Rede MLP, esta arquitetura demonstrou ser a melhor para realizar a predição das 180 operações futuras do módulo considerado. Com esses dados, uma manutenção preventiva pode ser devidamente agendada para que o Limite de degradação tolerável nunca seja ultrapassado.

4. Conclusões

Os modelos propostos se adequaram a situação experimental, mostrando ser possível aplicá-los no diagnóstico preditivo do módulo Contador do equipamento de automação bancária MMD. 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 sistema. O diagnóstico é um problema complexo, assim uma abordagem cognitiva na forma de Redes Neurais para possibilitar o tratamento dessa complexidade, sem deixar de lado a importância dos

processos estatísticos no pré-tratamento, foi aqui observada. Tanto a arquitetura MLP quanto a RBF obtiveram resultados satisfatórios para o problema propostos, porém a RBF demonstrou ser ótima em suas predições de estados futuros de degradação do equipamento. Os passos seguintes serão focados nas melhorias de dos resultados de ambas as arquiteturas de RNA estudadas e na aplicação do modelo proposto em outros Sistemas de Engenharia.

Referências

- [1] Cordier, M. O. Dague, P. Lévy, F. Montmain, J. Starowiecki., Marcel. Travé-Massuyès, L. 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, 2004.
- [2] Goldbarg, M. C. Luna, H. P. L. Otimização Combinatória e Programação Linear, Modelos e Algoritmos. Editora Campus, 2000.
- [3] Aguiar, M. A. Diagnóstico de falhas em equipamentos usando técnicas de Redes Neurais Artificiais. Dissertação de Mestrado, Escola Politécnica da USP, 2001.
- [4] Aguiar, M. A., Kovacs, Z. L. Destro, R. C., Pelaez, J. R., Simões, M. G. Predictive Maintenance Oriented Neural Network System - PREMON In: IECON'01, 2001, Denver, Colorado. Anais do IECON'01, 2001.
- [5] Bertalanffy, L. Von. General Theory of Systems. N. York, George Braziller. 1969.
- [6] Sochorov, M. General troubleshooting is NP-hard, 2000.
- [7] Haykin, S. Redes Neurais: Princípios e Prática. 2ª Ed; Porto Alegre: Bookman, 2001.
- [8] Kovacs, Z. L. Redes Neurais Artificiais: Fundamentos e Aplicações. 3ª Ed. São Paulo: Livraria de Física, 2002.
- [9] Fijany, A. Vatan, F. Barrett, A. Mackey, R. (2002) New Approaches for Solving the Diagnosis Problem. IPN. Progress Report, pag 42-149.
- [10] Silva Filho, R. I., Aguiar, M. A., Kovács, Z. L. Um Estudo de Caso Genérico de Diagnóstico Preditivo para Sistemas Complexos. Anais: IV SITRAER, São José dos Campos, 2005.