

# DETECÇÃO E ISOLAMENTO DE FALHAS EM UM SISTEMA DE NÍVEIS REAL

RAPHAELA GALHARDO FERNANDES\*, DIEGO RODRIGO CABRAL SILVA \*, LUIZ AFFONSO HENDERSON GUEDES DE OLIVEIRA\*, ADRIÃO DUARTE DÓRIA NETO\*

\* *Universidade Federal do Rio Grande do Norte. Natal, RN, Brasil*

Emails: raphaela@dca.ufrn.br, diego@dca.ufrn.br, affonso@dca.ufrn.br, adriao@dca.ufrn.br

**Abstract**— This work presents the development of a fault detection and isolation system applied to a system of real level connected by Fieldbus network. The system was developed using artificial neural networks and tested just as much in a simulated environment as in real environment intending to highlight difficulties found in real tests which there is not when one works only with simulation.

**Keywords**— Fault Detection and Isolation, Fault Diagnosis, Residual, Neural Networks.

**Resumo**— Este trabalho apresenta o desenvolvimento de um sistema de detecção e isolamento de falhas em um sistema de níveis real ligado a uma rede industrial Foundation Fieldbus. O sistema foi desenvolvido utilizando redes neurais artificiais e testado tanto em ambiente simulado quanto em ambiente real, no intuito de comprovar dificuldades encontradas em testes reais não existentes quando se trabalha apenas com simulações.

**Keywords**— Detecção e Isolamento de Falhas, Diagnóstico de Falhas, Resíduos, Redes Neurais.

## 1 Introdução

Cada vez mais cresce a necessidade de se garantir segurança e confiabilidade dos equipamentos utilizados na execução dos processos. Em um sistema dinâmico, as falhas podem causar alterações em parâmetros críticos do sistema, ou até mesmo mudanças em sua dinâmica. É bastante importante que os estados indesejados ou não permitidos do sistema sejam percebidos, de forma que se possa tomar ações apropriadas, evitando situações de perigo ou algum acidente.

Dessa forma, o ideal é que as falhas possam ser detectadas, isoladas e toleradas, proporcionando uma melhor confiabilidade do sistema. Detectar uma falha no sistema significa dizer se ela está ocorrendo ou não. Já isolar, significa classificar qual o tipo da falha, por exemplo, informar em que componente do sistema ela aconteceu, e a tolerância da falha pode ser definida como ações apropriadas que devem ser tomadas para minimizar o seu efeito. Todo este processo pode ser definido como Detecção e Diagnóstico de Falhas (DDF).

Para detectar e diagnosticar falhas eficientemente, é importante conhecer antecipadamente os padrões de falhas e as tendências do sinal para que elas ocorram, possibilitando uma detecção e diagnóstico de falhas mais exatas e uma redução nos custos de manutenção do processo.

Alguns métodos de detecção e diagnóstico de falhas são baseados na redundância física, ou seja, na duplicação de componentes de *hardware*, como sensores, atuadores e controladores. Nestes casos, as saídas dos pares de componentes equivalentes são comparadas para a detecção de falhas (Weber, 2002). Se os valores das saídas dos pares forem próximos, significa que não está ocorrendo falha, caso haja uma divergência entre eles, há falha.

Outras técnicas são baseadas no paradigma da redundância analítica. Com essa abordagem, pode-se utilizar um modelo matemático do sistema, baseado nas leis da física, para gerar sinais redundantes que são comparados aos sinais medidos pelos sensores físicos (Persin et al., 2002). Havendo uma diferença significativa entre as saídas, caracteriza-se a ocorrência de alguma falha.

Nos últimos anos, as pesquisas feitas no contexto dos Sistemas DDFs apresentam abordagens que utilizam os conceitos da Inteligência Artificial (IA), como por exemplo, Lógica *Fuzzy* (Uppal et al., 2005) ou Redes Neurais Artificiais (RNA's) (Shin et al., 2005).

Este artigo descreve o desenvolvimento de um sistema de Detecção e Isolamento de Falhas (DIF) aplicado a um sistema dinâmico em tempo real (uma planta composta por dois tanques, onde um deles tem o seu nível controlado). Basicamente, o sistema foi dividido em duas partes: a primeira corresponde à identificação neural do modelo da planta e a segunda, à detecção e isolamento (ou classificação) de falhas no processo.

A principal contribuição deste trabalho consiste no fato de que além dos testes, que foram realizados em um ambiente simulado, o sistema DIF foi implementado em uma planta industrial real. O sistema trabalha em regime de tempo real acusando as falhas no momento em que estas são detectadas, superando todas as dificuldades não encontradas em ambientes simulados.

## 2 Metodologia Desenvolvida

Neste trabalho foi desenvolvido um sistema DIF utilizando redes neurais, aplicado a um sistema de níveis. O esquema geral do funcionamento do sistema está exibido na Figura 1.

No caso, ao mesmo tempo que o sistema de níveis está em execução, um sistema elaborado a partir de RNAs procura fazer a sua identificação utilizando suas mesmas entradas ( $x(k)$ ). A cada instante, a saída do sistema de níveis ( $y(k)$ ) é comparada à saída do sistema de identificação ( $y'(k)$ ), gerando um valor de resíduo ( $r(k) = y(k) - y'(k)$ ) que será posteriormente utilizado no sistema de isolamento/classificação de falhas. Este último analisa os valores residuais e indica a ocorrência ou não de falhas e caso ocorra, qual o seu tipo.




Figura 1: Esquema Geral do Sistema DIF

Duas abordagens para identificação neural do sistema de níveis foram desenvolvidas e testadas (Fernandes et al., 2006), porém apenas uma delas foi aplicada ao sistema DIF. Na próxima seção, o sistema de níveis será apresentado e, posteriormente, os passos seguidos para a conclusão do sistema DIF aplicado ao mesmo.

### 3 Processo Utilizado: Sistema de Níveis

A Figura 2 mostra o sistema de níveis composto por dois tanques em cascata, representado em um modelo de 2ª ordem com uma entrada e uma saída. Para o controle do nível do tanque 2, é aplicada uma estratégia de controle Proporcional Integrativo Derivativo (PID) (Ogata, 1998).

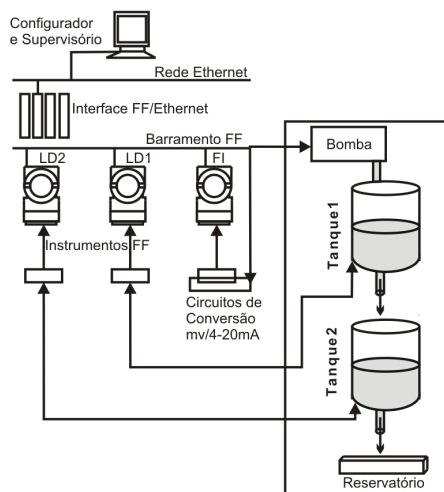


Figura 2: Arquitetura do Ambiente Real

A água que sai pelo orifício do tanque 1 cai dentro do tanque 2. Este por sua vez, também tem um orifício onde a água cai diretamente para o reservatório. Uma bomba é responsável por levar a água do reservatório para o tanque 1. Em cada

tanque existe um sensor de pressão *Foundation Fieldbus* (FF) (Lima et al., 2004), usado para medir os níveis correspondentes, ligados à rede *Fieldbus*. Além dos sensores de pressão, um conversor (FF/loop de corrente 4 a 20 mA) é usado para injetar sinais na bomba d'água.

A rede industrial *Foundation Fieldbus* é ligada a um computador supervisor através de interfaces de rede *Ethernet*. A partir deste computador é realizado todo o processo de configuração dos dispositivos, e o posterior monitoramento.

Os dados reais extraídos da planta para treinamento das redes neurais também foram captados da rede com o auxílio de softwares rodando neste computador. O padrão utilizado para comunicação entre o dispositivo mestre da rede FF e o computador configurador e supervisor é o OPC (*OLE for Process Control*) (Zheng and Nakagawa, 2002). O OPC é responsável por disponibilizar informações sobre a planta industrial no nível de supervisão para qualquer computador da rede. Além disso, permite a alteração de alguns parâmetros de configuração do sistema FF.

A identificação neural foi feita em dois ambientes: simulado e real. Para a simulação do comportamento da planta, utilizou-se o modelo matemático não linear descrito pelas equações 1 e 2, presentes no manual do fabricante da planta de níveis (Qua, n.d.).

$$\dot{L}_1 = -\frac{a_1}{A_1} \sqrt{2gL_1} + \frac{K_m}{A_1} V_p \quad (1)$$

$$\dot{L}_2 = -\frac{a_2}{A_2} \sqrt{2gL_2} + \frac{a_1}{A_2} \sqrt{2gL_1} \quad (2)$$

A Tabela 1 apresenta as descrições e valores dos parâmetros mostrados nas equações 1 e 2.

Tabela 1: Parâmetros da Planta

Nome	Significado	Valor
$K_m$	Constante da bomba	$4,6(\text{cm}^3/\text{s})/V$
$V_p$	Tensão aplicada à bomba	$-22 < V_p < 22$
$a_1$	Diâmetros da saída dos tanques 1 e 2	$0,178139\text{cm}$
$A_1$ e $A_2$	Áreas dos tanques 1 e 2	$15,5179\text{cm}^2$
$g$	Aceleração da Gravidade	$980\text{cm}/\text{s}^2$

Por fim, o modelo da planta de níveis juntamente com o controlador PID está ilustrado na Figura 3. Como é possível observar, o sinal de referência é o nível desejado para o tanque 2. O sinal desejado ( $d(k)$ ) é comparado ao nível atual do tanque 2 ( $L_2(k)$ ), gerando um erro ( $e(k)$ ) que é utilizado para o controlador PID para gerar um sinal de controle ( $V_p$ ) para a bomba que injeta água no tanque 1.

Na seção seguinte, serão apresentadas as abordagens desenvolvidas para a identificação neural e detecção e isolamento de falhas no sistema.




Figura 3: Planta de Níveis com Controlador PID

#### 4 Identificação do Sistema de Níveis

A identificação neural do sistema foi dividida em duas etapas: uma RNA para estimar o nível do tanque 1 (Etapa 1) e uma outra para estimar o nível do tanque 2 (Etapa 2). Os treinamentos das RNAs podem ser ilustrados pela Figura 4.




Figura 4: Estimativa dos Níveis dos Tanques 1 e 2. (a) Etapa 1. (b) Etapa 2.

A arquitetura da RNA 1, usada para estimar o nível do tanque 1, foi:

- Três nós na camada de entrada, onde as entradas são:  $V_p(k)$  e  $V_p(k-1)$  e  $L_1(k-1)$ ;
- Uma camada oculta com 3 neurônios com função de ativação sigmóide;
- Um neurônio na camada de saída (função de ativação linear), representando o nível do tanque 1 estimado no instante atual  $k$ ,  $L_1'(k)$ .

A arquitetura da RNA 2, usada para estimar o nível do tanque 2, foi:

- Dois nós na camada de entrada, onde as entradas são:  $L_1(k-1)$  e  $L_2(k-1)$ ;
- Uma camada oculta com 3 neurônios com função de ativação sigmóide;
- Um neurônio na camada de saída (função de ativação linear), representando o nível do tanque 2 estimado no instante atual  $k$ ,  $L_2'(k)$ .

Para implementar a estratégia de identificação neural do sistema de níveis, utilizou-se RNAs do tipo *Perceptron de Múltiplas Camadas* (MLP) (Haykin, 2001) que foram treinadas com o algoritmo *Backpropagation* (Haykin, 2001). O número de neurônios das camadas ocultas foi escolhido heurísticamente e os neurônios estão totalmente conectados.

A seguir será apresentado o desenvolvimento do sistema DIF aplicado ao sistema de níveis, baseado na identificação neural apresentada.

#### 5 Detecção e Isolamento de Falhas

Com a identificação neural apresentada, é possível obter dois resíduos,  $R_1$  e  $R_2$ , onde  $R_1 = L_1 - L_1'$  e  $R_2 = L_2 - L_2'$ . A estratégia para o isolamento das falhas pode ser vista na Figura 5. Neste caso, uma RNA, denominada RNA 3, é treinada recebendo como dados de entrada os valores de  $R_1$  e  $R_2$ . A saída da rede corresponde a um vetor de  $N + 1$  números, onde  $N$  é a quantidade de falhas que a rede será capaz de classificar. Por exemplo, considerando  $N = 3$ , ter-se-ia as possíveis saídas para a rede mostradas na Tabela 2.




Figura 5: Esquema Geral para Detecção e Isolamento das Falhas

Tabela 2: Saídas para Classificação de 3 Falhas

Situação Normal	1	0	0	0
Falha 1	0	1	0	0
Falha 2	0	0	1	0
Falha 3	0	0	0	1

Considerando os dois resíduos para detectar e isolar as falhas, o sistema DIF poderia detectar no máximo 8 falhas diferentes, onde a situação em que  $R_1 = 0$  e  $R_2 = 0$  seria comportamento normal do sistema. Para fins de testes, conseguiu-se prever cinco tipos de falhas com conjunto de resíduos distintos. A Tabela 3 mostra os tipos de falhas selecionados para análise dos resultados, onde + representa o resíduo positivo, - o resíduo negativo e 0 o resíduo igual ou muito próximo a zero.

Como o classificador neural trabalha em cima de valores positivos, negativos e nulos para os resíduos, ele poderia ter sido traduzido em um conjunto de regras com sentenças condicionais. Por exemplo, se  $R_1$  for positivo e  $R_2$  negativo, bastaria fazer um teste condicional e indicar que a falha 2 está ocorrendo. Por outro lado, se um outro sistema dinâmico pudesse ser modelado por  $N$  resíduos, onde  $N$  é um valor muito grande, ficaria um pouco trabalhoso codificar diversas sentenças condicionais para informar a falha. Além disso, o neural pode classificar falhas com resíduos semelhantes (duas falhas diferentes com mesmos  $R_1$  e  $R_2$ , por ex.,  $R_1 = +$  e  $R_2 = 0$ ), porém com amplitudes diferentes, sem a necessidade de um novo teste condicional verificando o limiar da falha.

Tabela 3: Disposição dos Resíduos

Falha	Descrição	$R_1$	$R_2$
	Ausência de Falha	0	0
1	Novo orifício no tanque 1. Água não cai no tanque 2	-	0
2	Diminuição do orifício do tanque 1	+	-
3	Diminuição do orifício do tanque 2	-	+
4	Aumento do orifício do tanque 2	0	-
5	Fluxo extra de água no tanque 1	+	0

## 6 Resultados da Identificação Neural

Os dados captados para treinamento foram gerados a partir do funcionamento normal da planta de níveis, ou seja, aplicou-se sinais de referências para o nível do tanque 2 e o sinal de controle era gerado pelo controlador PID. Os sinais de referências eram do tipo degrau unitário ou senóide, com amplitude variando ao longo do tempo. Foram realizados testes tanto utilizando dados simulados quanto dados reais (Fernandes et al., 2006). Apenas resultados com dados reais serão apresentados neste artigo.

Após o treinamento das duas redes utilizadas pela a identificação neural, os erros quadráticos médios obtidos para a RNA 1 e a RNA 2 foram de aproximadamente,  $10^{-4} \text{ cm}^2$  e  $10^{-5} \text{ cm}^2$ , respectivamente. Um exemplo da identificação neural para dados não apresentados no treinamento das redes pode ser visto na Figura 6. No primeiro gráfico estão os níveis do tanque 1 real (azul) e o gerado pela RNA 1 (vermelho) ao longo do tempo. No segundo, é possível observar o nível do tanque 2 real (azul), o gerado pela RNA 2 (vermelho) e a referência a ser seguida para o nível deste mesmo tanque (verde). Por fim, no último gráfico são apresentados os valores residuais  $R_1$  (azul) e  $R_2$  (vermelho).




Figura 6: Exemplo de Identificação Neural

Com base nos resultados obtidos, pode-se inferir que, para ambas situações, os erros entre os níveis dos tanques e os gerados nas identificações são maiores durante o período transitório do nível do tanque 2. Isto acontece devido ao fato de muitos ruídos estarem presentes durante os testes e a bomba possui uma dinâmica bastante não linear, dificultando o aprendizado das redes neurais.

Os três gráficos presentes nas Figuras 7, 8 e 9 apresentam outros resultados da identificação neural do sistema. Eles permitem uma análise sobre o que é mais próximo do funcionamento real do sistema, se o modelo matemático ou a RNA treinada a partir dos dados reais. Vale salientar, que os mesmos ganhos para o controlador PID foram aplicados tanto ao controlador da planta real quanto ao do modelo matemático.

O 1º gráfico da Figura 7 apresenta o nível do tanque 1 do sistema real (em azul), o mesmo gerado pela RNA 1 de identificação (em vermelho) e o nível gerado pelo modelo matemático considerando a mesma referência. O 2º gráfico mostra os erros entre o nível real e o gerado pelo modelo matemático (em azul) e o nível real e o gerado pela RNA 1 de identificação (em vermelho).

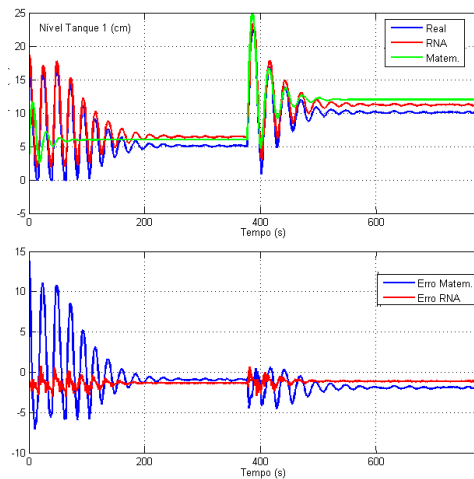


Figura 7: Diferenças do Nível do Tanque 1: Modelo Matemático, Real e Gerado pela RNA

Na Figura 8, o 1º gráfico apresenta o nível do tanque 2 do sistema real (em azul), o mesmo gerado pela RNA 2 de identificação (em vermelho) e o nível gerado pelo modelo matemático considerando a mesma referência. Da mesma forma que anteriormente, o 2º gráfico mostra os erros entre o nível real e o gerado pelo modelo matemático (em azul) e o nível real e o gerado pela RNA 2 de identificação (em vermelho).

Por fim, a Figura 9 exhibe os sinais de controle gerados pelo funcionamento real da planta (primeiro gráfico, em azul) e pelo modelo matemático (primeiro gráfico, em vermelho), bem como a diferença entre eles (segundo gráfico).

A partir deste três últimos gráficos, pode-




Figura 8: Diferenças do Nível do Tanque 2: Modelo Matemático, Real e Gerado pela RNA




Figura 9: Diferenças do Sinal de Controle: Modelo Matemático e Real

se concluir que os dados gerados pela identificação neural são bem mais próximos da realidade do que os gerados pelo modelo matemático disponível. Observa-se também que com o modelo matemático o nível do tanque 2 estabiliza mais rapidamente, devido ao fato das equações matemáticas modelarem uma situação ideal, sem considerar ruídos e sem considerar uma maior não-linearidade da bomba (o que acontece no caso real).

## 7 Resultados do Sistema DIF

A rede neural, RNA 3, utilizada para detectar e isolar as falhas foi treinada apenas utilizando os resultados de identificação neural utilizando o modelo matemático do sistema (Fernandes et al., 2006). De posse do modelo matemático, falhas foram simuladas e os resíduos captados, permitindo a geração de dados que significassem fun-

cionamento normal do sistema ou ocorrência de falha. Essa abordagem foi escolhida devido ao fato de que em situações reais, onde não se tem uma base de dados com informações de falhas ocorridas ao longo do tempo, poderia ficar complicado gerar falhas no sistema para assim poder desenvolver um aplicativo que pudesse detectá-las.

A Figura 10 apresenta o supervisor desenvolvido para acompanhar o funcionamento do sistema. Nele é possível observar a ocorrência ou não de falhas no sistema de acordo com a estratégia descrita na seção 5.




Figura 10: Tela do Supervisor Real

Em tempo real, são exibidos os valores instantâneos dos níveis dos tanques reais, assim como os níveis estimados pelas redes neurais e os valores dos resíduos. O supervisor também exibe um gráfico com a evolução dos valores residuais ao longo do tempo. Caso alguma falha ocorra, o botão com a falha correspondente aparecerá em vermelho e uma mensagem informando a consequência da falha é exibida.

Os três gráficos das Figuras 11, 12 e 13 ilustram o momento em que as falhas do tipo 2, 3 e 5 ocorrem (ver Tabela 2). Neste momento, os resíduos divergem dos valores próximos de zero e a RNA 3 é capaz de identificar e classificar a falha. Neste momento, o botão correspondente à falha muda para a cor vermelha e as mensagens “Acúmulo de água no tanque 1 e diminuição do fluxo de água para o tanque 2”, “Acúmulo de água no tanque 2 e diminuição de água no tanque 1” e “Acúmulo de água no tanque 1” são exibidas para as falhas 2, 3 e 5, respectivamente.

Como já citado, a estratégia do sistema DIF foi implementada tanto no ambiente simulado quanto no real. Trabalhando com o sistema real muitas dificuldades surgiram, por exemplo: os testes deveriam ser feitos considerando que a água no tanque 1 não transbordasse; necessidade de uso de equipamentos extras (fonte, módulo amplificador, etc.); existência de vazamentos entre as mangueiras e os medidores de pressão; problemas na identificação neural em momentos transitórios devido à não-linearidade da bomba (modelada de

forma ideal), entre outros.




Figura 11: Falha 2 - Orifício do Tanque 1 Menor

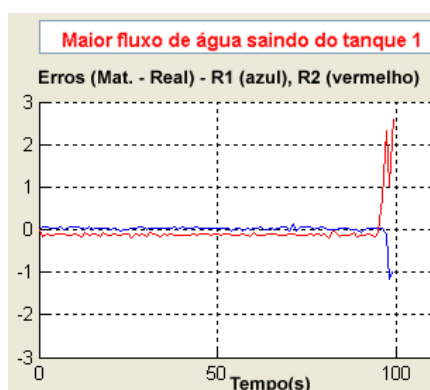


Figura 12: Falha 3 - Orifício do Tanque 2 Menor

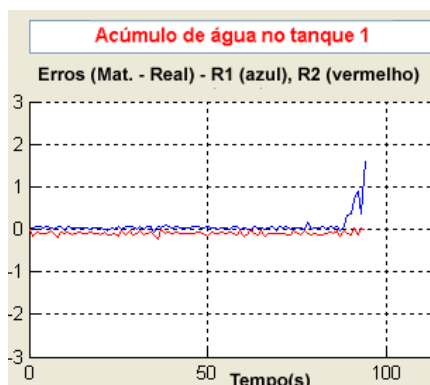


Figura 13: Falha 5 - Água Extra no Tanque 1

## 8 Conclusões e Perspectivas

Neste trabalho mostrou-se o desenvolvimento de uma sistema de detecção e isolamento de falhas em um sistema de níveis real ligado à uma rede industrial Foundation Fieldbus. Este sistema foi dividido em duas partes: identificação neural e classificação/isolamento de falhas. Este sistema é executado em regime de tempo real e é capaz de acusar as falhas no momento em que as anorma-

lidades ocorrem, superando todas as dificuldades não encontradas em ambientes simulados.

Resultados da identificação do sistema real com o modelo matemático e com redes neurais foram apresentados, mostrando que o neural apresentou resultados mais próximos da realidade. Isso deve-se ao fato do modelo matemático apresentar uma situação ideal do funcionamento do sistema, o que não ocorre na realidade.

Como perspectivas, pretendem-se melhorar o identificador neural para situações em que o nível do tanque 2 ainda não esteja estabilizado. Além de incrementar o classificador neural para que seja capaz de detectar e isolar falhas com comportamentos semelhantes para os resíduos  $R_1$  e  $R_2$ .

## Referências

- Fernandes, R. G., Silva, D. R. C., de Oliveira, L. A. H. G. and Neto, A. D. D. (2006). Identificação neural de um sistema de níveis em ambiente foundation fieldbus, *Congresso Latino Americano de Automática*.
- Haykin, S. (2001). *Redes neurais: princípios e prática*, 2nd edn, Bookman.
- Lima, F., Guedes, L. A., Ortiz, A. and Maitelli, A. (2004). Hybrid environment for tests and training in fieldbuses, *VI Conferência Internacional de Aplicações Industriais - Induscon*, pp. 1-6.
- Ogata, K. (1998). *Engenharia de Controle Moderno*, LTC.
- Persin, S., Tovornik, B., Muskinja, N. and Valh, D. (2002). Increasing process safety using analytical redundancy, *Electrotechnical Review*, pp. 240-246.
- Qua (n.d.). *Coupled Water Tank Experiments*.
- Shin, H. J., Eom, D.-H. and Kim, S.-S. (2005). One-class support vector machines - an application in machine fault detection and classification, *Computer and Industrial Engineering* pp. 395-408.
- Uppal, F. J., Patton, R. J. and Witczak, M. (2005). A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the damadics benchmark problem, *Control Engineering Practice*.
- Weber, T. S. (2002). Um roteiro para exploração dos conceitos básicos de tolerância a falhas, *Technical report*, Instituto de Informática UFRGS.
- Zheng, L. and Nakagawa, H. (2002). Opc (ole for process control) specification and its developments, *41st SICE Annual Conference*, Vol. 2, pp. 917-920.