

DETECÇÃO E DIAGNÓSTICO DE FALHAS EM SENSORES DE UMA REDE INDUSTRIAL FOUNDATION FIELDBUS UTILIZANDO SISTEMAS INTELIGENTES

Luiz Gustavo Santos Bezerra¹, Daniel Lopes Martins¹, Adrião Duarte Dória Neto¹, Jorge Dantas de Melo¹.

1. *DCA – Departamento de Engenharia de Computação e Automação
UFRN – Universidade Federal do Rio Grande do Norte
Natal, Rio Grande do Norte, Brasil.*

E-mails: luiz122@hotmail.com, danlartin@dca.ufrn.br, adriao@dca.ufrn.br, jdmelo@dca.ufrn.br

Abstract— This work presents the study of the development of a detector and fault diagnostician in sensors using intelligent algorithms embedded in industrial network Foundation Fieldbus. The algorithms used for solving the problem were artificial neural networks and fuzzy logic, which performs the detection and diagnosis of faults dynamically, considering four existing types of failures that can exist. The neural network has been developed according to the architecture of the NARX model, making the prediction of steps. Fuzzy logic has been used as a fuzzy classifier to perform the classification and diagnosis of faults.

Keywords— Intelligent Systems, Sensors and Actuators in Automation, Smart Automation, Diagnosis and Fault Detection.

Resumo— Este trabalho de conclusão de curso apresenta o estudo do desenvolvimento de um detector e diagnosticador de falhas em sensores utilizando algoritmos de sistemas inteligentes embarcados na rede industrial Foundation Fieldbus. Os algoritmos utilizados para a solução do problema foram rede neural artificial e lógica fuzzy, que realizam a detecção e diagnóstico de falhas dinamicamente, considerando quatro tipos existentes de falhas que podem ocorrer. A rede neural foi desenvolvida de acordo com a arquitetura do modelo NARX, realizando a previsão dos passos. A lógica fuzzy foi utilizada como classificador fuzzy para realizar a classificação e diagnóstico das falhas.

Palavras-chave— Sistemas Inteligentes, Sensores e Atuadores em Automação, Automação Inteligente, Diagnóstico e Detecção de Falhas.

1. Introdução

Com o progresso no controle distribuído e modelos de sistemas de controle preditivos, os benefícios para os diversos segmentos industriais, tais como química, petroquímica, indústrias de cimento, aço, energia e dessalinização têm sido enormes. No entanto, uma tarefa de controle muito importante na gestão de plantas de processo ainda permanece em grande parte uma atividade manual, realizada por operadores humanos. Esta é uma tarefa caracterizada por eventos anormais em um processo. Isso envolve a detecção adequada de um evento anormal, diagnosticar suas origens causais e, em seguida, tomar decisões adequadas de controle de supervisão e ações para trazer o processo de volta ao normal. Toda essa atividade passou a ser chamado de Gestão de Evento Anormal (AEM – Abnormal Event Management), um componente-chave de controle de fiscalização (Venkatasubramanian, Rengaswamy, Yin, & Kavuri, 2003).

A AEM é constituída por um conjunto de procedimentos que aborda a detecção, diagnóstico e correções das condições inadequadas que geram as falhas em um processo. Realizar o “AEM” significa a possibilidade de detectar as falhas com a planta trabalhando em uma região de segurança operacional, de maneiras a evitar a progressão do evento e a consequente perda de produtividade (Silva G. S., 2008).

No entanto, essa total confiança nos operadores humanos para lidar com tais eventos anormais e de emergência tornou-se cada vez mais difícil, devido a vários fatores. Essa dificuldade é devido à ampla gama de

atividade de diagnóstico que compreende uma variedade de disfunções tais como, falhas nas unidades de processo, degradação da unidade de processamento, derivas de parâmetros e assim por diante. Ainda é mais complicado pelo tamanho e complexidade de plantas de processo moderno. Além disso, muitas vezes a ênfase é no diagnóstico rápido que coloca certas restrições e exigências sobre a atividade de diagnóstico. Onde a tarefa de diagnóstico de falhas é dificultada pelo fato de que as medições do processo podem muitas vezes ser insuficiente, incompleta e/ou pouco confiáveis devido a uma variedade de causas, tais como falhas em sensores.

Estima-se que a indústria petroquímica nos EUA têm aproximadamente 20 bilhões de dólares em perdas anuais devido a uma má AEM. O custo é maior quando inclui situações semelhantes em outras indústrias, como farmacêutica, especialidades químicas, alimentação, e assim por diante (NIMMO, 1995).

Esse é o próximo grande desafio para engenheiros de controle. No passado, a comunidade de controle mostrou como controle regulamentar poderia ser automatizado usando computadores e, assim, retirá-lo das mãos de operadores humanos. Isso resultou em um grande progresso na qualidade e consistência do produto, segurança do processo e eficiência do processo. O desafio atual é a automação da AEM, fazendo a utilização de sistemas inteligentes, proporcionando assim operadores humanos para assistência na área. A comunidade das indústrias de processos vê isso como o próximo grande marco na pesquisa e aplicação de sistemas de controle (Venkatasubramanian, Rengaswamy, Yin, & Kavuri, 2003).

2. Fundamentação Teórica

2.1. Foundation Fieldbus

O Fieldbus é um protocolo desenvolvido para automação de Sistemas de Fabricação, elaborado pela Fieldbus Foundation e normalizado pela ISA - International Society of Automation. O protocolo Fieldbus visa à interligação de instrumentos e equipamentos, possibilitando o controle e monitoração dos processos. Geralmente é utilizado com os softwares supervisórios, que permitem a aquisição e visualização desde dados de sensores, atuadores até status de equipamentos.

Os blocos funcionais são objetos de software com funções pré-programadas, contendo alguns parâmetros internos, que podem ou não serem ajustados pelo usuário, e entradas e saídas que são interligadas para realizar as lógicas de controle (Martins, 2011).

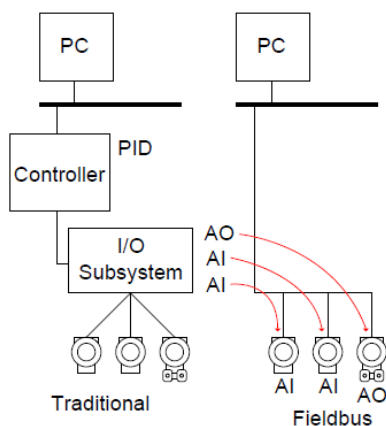


Figura 1 - Simplificação da rede Foundation Fieldbus.

2.2. Redes Neurais Artificiais - NARX

O modelo NARX (Nonlinear AutoRegressive model with eXogenous inputs) baseia-se em uma rede MLP, cuja a entrada consiste da própria saída realimentada com atrasos no tempo e uma entrada exógena, também com atrasos. Nesta arquitetura, as saídas estimadas da rede são introduzidas novamente às entradas, assim permitindo implementar a predição de passos múltiplos.

A rede dinâmica NARX é uma importante classe de sistemas não lineares de tempo discreto, que é matematicamente representada pelo seguinte modelo.

$$y(n) = f[y(n-1), \dots, y(n-dy), u(n), u(n-1), \dots, u(n-du+1)] \quad (1)$$

2.3. Classificador Fuzzy

Os classificadores nebulosos baseados em regras são semelhantes ao sistema de controle fuzzy. Os classificadores fuzzy podem ser divididos em três estágios, que são fuzzyficação, inferência e desfuzzyficação. Levando a tona a técnica de controladores nebulosos proposta por Mamdani.




Figura 2. Estrutura do Classificador Fuzzy.

3. Detecção e Diagnóstico de Falhas em Sensores

Falha em sensores caracteriza-se por um funcionamento não coerente de qualquer componente de um sistema, ocasionando uma perda de desempenho até a total parada de execução de suas funções.

Um entendimento dos tipos de falhas e de seus padrões de sinal associados é muito importante para os métodos de classificação de falhas em sensores. Para facilitar o estudo dos algoritmos será abordada a classificação encontrada por (Zhang & Yan, 2001).

A idealização de uma detecção e diagnóstico de falhas em sensores é fornecer uma informação adequada e coerente ao nível real observado, para consequentemente caso ocorra uma falha no sensor, as ações adequadas sejam realizadas. Para o determinado projeto, o processo de detecção e diagnóstico foi resumido em duas fases, detecção de falha e classificação de falha.

3.1. Algoritmos para Classificação de Falhas

As ferramentas de IA mais utilizadas para detecção e diagnóstico de falhas em sensores são: sistemas especialistas, lógica nebulosa e redes neurais artificiais. No presente trabalho a ferramenta utilizada para a detecção e diagnóstico de falhas foi lógica nebulosa.

Existem várias falhas provenientes dos dois tipos de falhas possíveis em um sensor:

- Ausência de falha: o sensor está em funcionamento normal.
- Valor zero: o sensor fornece o valor constante zero.
- Valor de fundo de escala: o sensor fornece o valor de fundo de escala do determinado sensor.
- Deriva de *offset*: é adicionado um sinal de *offset* ao sinal do sensor.
- Deriva de escala: o fator de escala do sensor se altera ao longo do tempo.

A detecção da presença de falhas é resultado de uma análise entre o valor real e o valor predito obtido, de acordo com as entradas definidas na. Desta forma o classificador calcula duas informações, a variação da medição do sinal real e a variação da medição do sinal predito.

A falha ocorre quando o valor real é alterado significativamente e o valor estimado permanece inalterado durante o tempo equivalente aos passos de predição.




Figura 3. Diagrama de blocos do diagnóstico de falhas.

No presente trabalho foi utilizada uma rede neural do tipo NARX para realizar a previsão do sinal. Para realizar a classificação da falha, foi desenvolvido um classificador fuzzy, tendo como entrada o sinal real e o sinal estimado, e com entrada o diagnóstico da falha ocorrida no sensor.

4. Desenvolvimento e Resultados

4.1. Sistema de Tanques

Para realização de testes foi utilizada uma planta composta por um sistema de tanques, que é um kit didático fabricado pela empresa Quanser. A planta é composta por dois tanques de 30 cm, colocados um sobre o outro de forma que a água escoar do tanque de cima para o de baixo através de um orifício, denominando assim o tanque de cima como *tanque 1* e o de baixo *tanque 2*. Para realizar a captação do nível, a planta originalmente possuía um sensor de nível em cada tanque, mas seus sensores padrões foram removidos para trabalhar com sensores industriais de nível.

A bomba também foi substituída, sendo utilizada uma bomba de para-brisas de carro (12 V, 4 A). Esse sistema recebe um sinal de tensão originário do FI (conversor FF para corrente), que disponibiliza um sinal de 4 a 20 mA que é convertido por um circuito.

4.2. Implementação do Preditor Neural Aplicado ao Ambiente Foundation Fieldbus

Primeiramente foram aplicados e coletados valores do sistema de tanques através da comunicação OPC, onde esses dados adquiridos foram utilizados para realizar o treinamento da RNA. Para realizar a coleta de dados foram inseridas periodicamente tensões na bomba, de forma randômica, e coletando os níveis dos dois tanques, assim formando uma base de dados contendo a dinâmica do sistema. A base de dados foi composta por 917 amostras de tensão e níveis dos tanques 1 e 2. A arquitetura da rede NARX contém cinco atrasos para cada entrada, uma camada oculta contendo cinco neurônios e apresentando como saída o nível dos dois tanques. Na arquitetura não foi utilizada uma realimentação da saída como entrada pelo motivo da possibilidade de acúmulo de erro.

Para realizar o treinamento foi utilizado o algoritmo backpropagation proposto por Levenberg-Marquardt e com a determinada arquitetura alcançou um erro médio quadrático (MSE) próximo à ordem de 10^{-2} após 200 épocas de treinamento.




Figura 4. Erro médio quadrático (MSE).

A partir dos pesos e bias adquiridos da simulação no MATLAB foi possível configurar a rede no ambiente FF. Foram utilizados seis blocos aritméticos para poder montar um neurônio, sendo totalizados trinta blocos aritméticos para os cinco neurônios. Essa grande quantidade de blocos é por causa da limitação de três entradas por bloco aritmético e a grande quantidade de entradas, sendo três entradas e cinco atrasos para as respectivas entradas. Para as funções de ativação foram utilizados três blocos caracterizadores de sinal. Nas imagens abaixo, Figura 5 e Figura 6, é apresentada a arquitetura da RNA no ambiente FF.

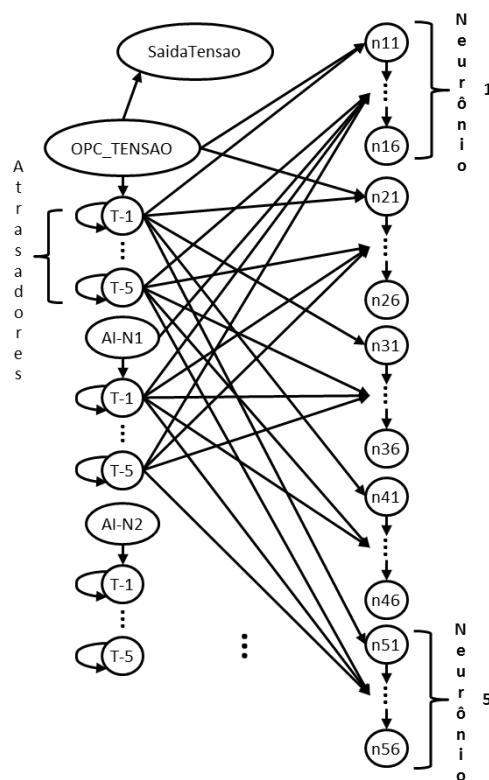


Figura 5. Arquitetura das entradas e camada oculta.




Figura 6. Arquitetura da camada oculta e de saída com a função de ativação.

4.3. Implementação do Classificador Fuzzy Aplicado ao Ambiente Foundation Fieldbus

Foi determinado como entradas do classificador fuzzy o sinal real e sinal estimado (proveniente do preditor neural).

Foram determinadas cinco funções de pertinência para a entrada real e sete funções de pertinência para a entrada estimada. Na saída, foram determinadas quatro saídas, que são: fundo de escala, erros de deriva, valor zero e sem falha. De acordo com a pesquisa realizada, acontecem dois tipos de erros de deriva, deriva de escala e deriva de *offset*, mas no presente trabalho foi resumido em apenas um tipo de erro (de deriva) pelo fato de ambos os tipos de falhas apresentarem características semelhantes, e consequentemente dificultando a decisão de classificação entre deriva de escala e *offset*.

As funções de pertinência da saída foram configuradas de forma a obter uma maior semelhança com um *singleton*, característica essa possível de ser implementada no ambiente FF.




Figura 7. Função de pertinência de entrada do sinal real.

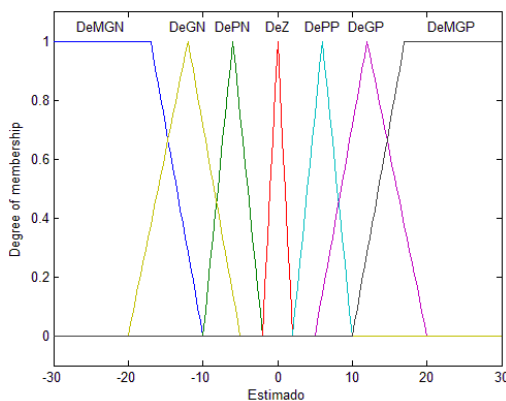


Figura 8. Função de pertinência de entrada do sinal estimado.

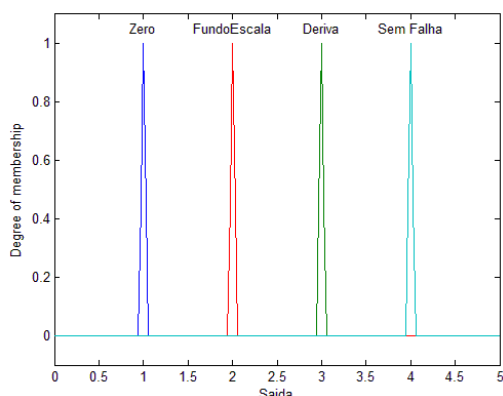


Figura 9. Função de Pertinência da saída.

No estágio de inferência foram escolhidos os métodos do cálculo mínimo e do máximo para saída. A base de regras contém no total de 35 regras.

Tabela 1. Base de Regras do classificador fuzzy.

$\Delta\hat{y}(n)$ \ $\Delta y(n)$	Grande Negativo	Pequeno Negativo	Zero	Pequeno Positivo	Grande Positivo
Muito Grande Negativo	Fundo de Escala	Fundo de Escala	Fundo de Escala	Fundo de Escala	Fundo de Escala
Grande Negativo	Deriva	Deriva	Fundo de Escala	Deriva	Fundo de Escala
Pequeno Negativo	Deriva	Deriva	Deriva	Deriva	Deriva
Zero	Sem Falha	Sem Falha	Sem Falha	Sem Falha	Sem Falha
Pequeno Positivo	Deriva	Deriva	Deriva	Deriva	Deriva
Grande Positivo	Zero	Deriva	Zero	Deriva	Deriva
Muito Grande Positivo	Zero	Zero	Zero	Zero	Zero

Após a etapa de realização de testes no *simulink* do MATLAB, foi dado início a implementação do *Classificador Fuzzy* por meio de blocos funcionais, criando todos os estágios do classificador fuzzy aplicado ao ambiente FF.

Para uma melhor estrutura o classificador foi separado em cinco módulos no software SYSCON da Smar, que são os módulos: *EntradasFuzzy*, *Fuzzyficação*, *InferenciaMin*, *InferenciaMax* e *Desfuzzyficação*. Inicialmente o módulo de *Entradas Fuzzy* apresenta a finalidade de estruturar e tratar os sinais para que sirva de entradas ao classificador, no caso o módulo faz o tratamento para resultar na variação dos sinais de entrada ($\Delta y(n)$ e $\Delta\hat{y}(n)$). A Figura 10 demonstra a estrutura do bloco *EntradasFuzzy*, onde o bloco *AI_TANQUE1* representa o sinal do nível do tanque superior, o bloco *ns12* representa o neurônio proveniente da primeira saída do *Preditor Fuzzy-FF*, onde o bloco *ns12* representa o sinal estimado.




Figura 10. Módulo EntradasFuzzy.

Após o módulo de tratamento dos sinais para as entradas do classificador, foi criado o módulo *Fuzzyficação*, que têm como finalidade realizar o estágio de fuzzyficação do classificador. A Figura 11 representa o módulo de *Fuzzyficação*, do tipo CHAR, simulam as funções de pertinência.

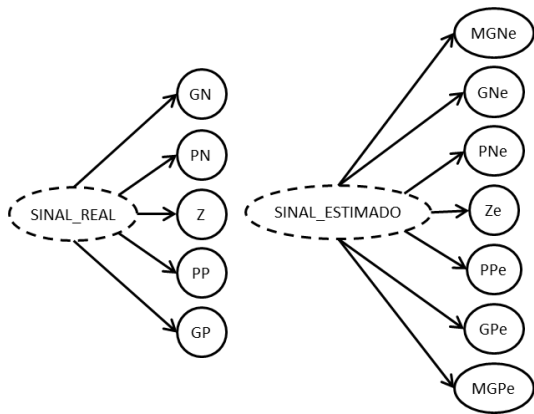


Figura 11. Módulo Fuzzyficação.

No estágio de inferência, que está incluído a base de regras, foi separado em dois módulos, *InferenciaMin* e *InferenciaMax*, que são responsáveis pelo processo de inferência. A Figura 12 apresenta o módulo *InferenciaMin*, onde as 35 regras estão representadas pelos blocos do tipo ISEL, que estão nomeados de R1 a R35.

A Figura 13 e Figura 14 apresentam o módulo *InferenciaMax*, onde estão implementadas as quatro funções de pertinência do tipo *singleton* da saída do classificador, no tipo de bloco ISEL. Por causa limitação existente de quatro entradas no bloco ISEL, para o determinado caso, houve a necessidade da criação blocos para auxiliarem a formação das funções de pertinência.




Figura 12 - Módulo InferênciaMin.

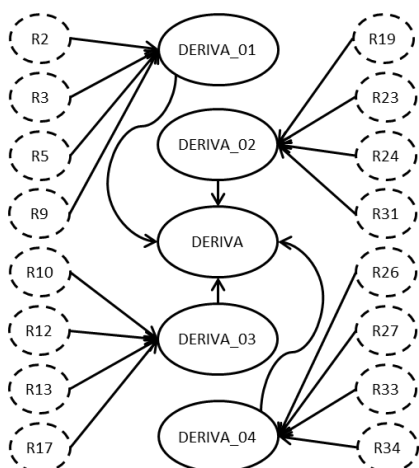


Figura 13 - Módulo InferênciaMax.

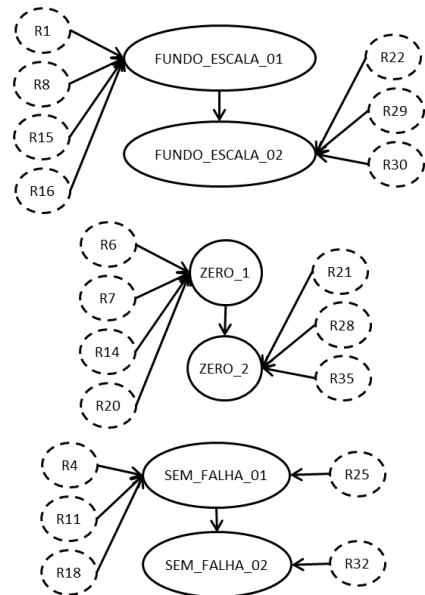


Figura 14 - Módulo InferênciaMax.

O módulo *Desfuzzyficacao* tem a finalidade de realizar o processo da desfuzzyficação do *Classificador Fuzzy-FF*. A Figura 15 apresenta o módulo *Desfuzzyficacao*. O resultado da classificação fuzzy é dado pela saída OUT do bloco *DIVISOR*.

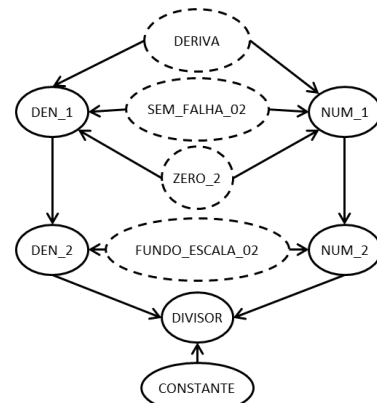


Figura 15 - Módulo Desfuzzyficação.

4.4. Resultados

Primeiramente foi realizada a coleta dos dados da saída do *Preditor Neural-FF* e foi verificado que a predição conseguiu acompanhar os níveis dos tanques 1 e 2, ou seja, realizar a predição. Embora, o sinal predito não tenha sido tão satisfatório por causa do surgimento de uma oscilação não desejada. O motivo da oscilação na estimação provavelmente tenha sido ocasionado pelo sinal de entrada que estava composto no treinamento. Quando foi realizada a coleta de dados para compor a base de dados e conseqüentemente servir de entrada para o treinamento da RNA, foi verificada uma oscilação insatisfatória nos níveis dos tanques resultante de tensão na bomba que alimentava o sistema, ou seja, falhas no hardware, onde pode ser verificado na **Erro! Fonte de referência não encontrada.** e **Erro! Fonte de referência não encontrada.** essa oscilação. Apesar do sinal de predição não ter sido de forma bastante satisfatória, esse é um fato que não interferiu no resultado final do projeto, que é realizar detecção e diagnóstico de falhas em sensores.

Para coletar os sinais do *Classificador Fuzzy-FF*, foram simulados os quatro tipos de falhas no sinal real que são: falha do tipo zero, fundo de escala, deriva e sem falha. Foi possível verificar que o sistema de classificação fuzzy no ambiente FF se comportou corretamente e de acordo com a simulação realizada no MATLAB, conseguindo detectar e diagnosticar corretamente o tipo de falha ocasionada no determinado momento.

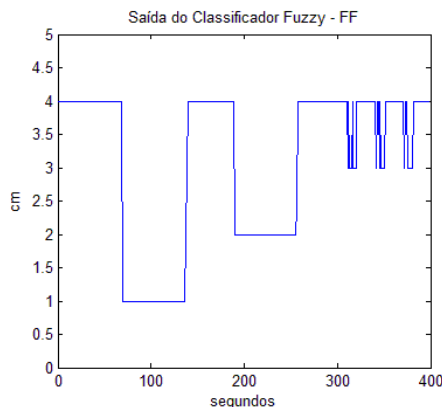


Figura 16 – Sinal de saída do Classificador Fuzzy.

O gráfico da Figura 17 apresenta a sobreposição dos sinais, dando melhor noção da classificação dos tipos de falhas.

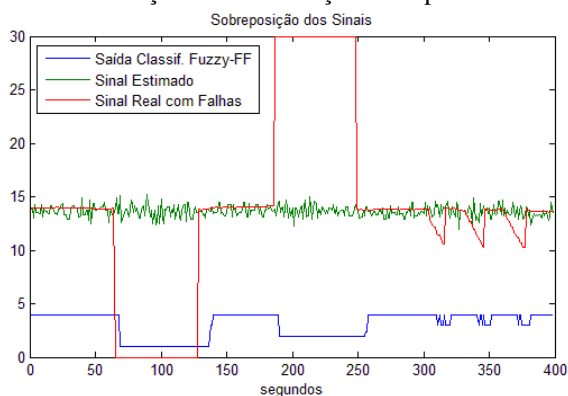


Figura 17 - Sobreposição dos sinais do Classificador Fuzzy.

5. Conclusão

Neste trabalho é desenvolvida uma estratégia fazendo o uso de algoritmos inteligentes, mais especificamente lógica nebulosa e rede neural, para monitorar o funcionamento de sensores, em nível de campo, realizando a tarefas de detecção de falhas e principalmente a análise de qual tipo de falha está sendo ocasionada no momento, ou seja, informando um diagnóstico sobre a falha no sensor. Ao total foram abordados quatro tipos comuns de falhas em sensores.

Existem técnicas de sistemas inteligentes que tem a capacidade de otimizar a classificação fuzzy, que é o caso dos algoritmos genéticos, onde pode ser utilizado para um melhor ajuste das funções de pertinência, assim refletindo diretamente em um melhor resultado de classificação. Outra forma de otimizar o desempenho do classificador fuzzy é com o aumento de regras, aonde isso resulta no aumento da quantidade de funções de pertinência tanto na entrada como na saída. Embora, vale salientar que com o aumento de regras pode ocasionar em um aumento significativo na implementação do classificador, tendo em vista que há uma limitação de

hardware quando se trata de embarcação sistemas, onde no presente projeto é embarcado em instrumentos FF.

De acordo com a definição de uma AEM, para trabalhos futuros além da realização da detecção e diagnóstico de falhas, seria possível realizar a correção das mesmas. A partir da detecção e diagnóstico é possível realizar a correção através de uma realimentação do sinal, de forma a compensar o determinado sinal com falha, resultando na correção do mesmo tendo como base o sinal de saída da predição.

Agradecimentos

Agradeço primeiramente a Deus, pelo dom da vida, da saúde, do amor e da sabedoria.

Ao meu professor orientador Dr. Adrião Duarte e ao Msc. Daniel Martins, por terem me orientado.

Aos amigos do DCA e LAMP.

A CNPq, pelo apoio financeiro.

6. Referências Bibliográficas

- Haykin, S. S. (2001). *Redes Neurais - Princípios e Prática* (2ª ed.). Bookman.
- Kuncheva, L. I. (2000). *Fuzzy Classifier Design* (Vol. 49). New York: Physica-Verlag.
- Martins, D. L. (2011). *Arquitetura de Controladores Fuzzy em Redes Foundation Fieldbus*. Universidade Federal do Rio Grande do Norte, Natal.
- Medeiros, J. P. (2009). *Estudo e Implementação de Algoritmos Inteligentes para Detecção e Classificação de Falhas na Medição de Gás Natural*. Universidade Federal do Rio Grande do Norte, Natal.
- Mendel, J. M. (Março de 1995). Fuzzy Logic Systems for Engineering: A Tutorial. *Proceedings of the IEEE*, 83, 345-377.
- NIMMO, I. (Setembro de 1995). Adequately address abnormal operations. *Chemical Engineering Progress*, 91(9), 36-45.
- Silva, D. R. (2005). *Redes Neurais Artificiais no Ambiente de Redes Industriais Foundation Fieldbus Usando Blocos Funcionais Padrões*. Universidade Federal do Rio Grande do Norte, Natal.
- Silva, G. S. (2008). *Aplicação a Um Reator de Hidrotratamento de Método de Detecção e Diagnóstico de Falhas Baseado em Modelo*. Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Venkatasubramanian, V., Rengaswamy, R., Yin, K., & Kavuri, S. N. (22 de Abril de 2003). A review of process fault detection and diagnosis Part I: Quantitative model-based methods. *Computers and Chemical Engineering*, pp. 293-311.
- Weber, L., & Klein, P. A. (2003). *Aplicação da Lógica Fuzzy em Software e Hardware* (1ª ed.). ULBRA.
- Zhang, H. Q., & Yan, Y. (Outubro de 2001). A wavelet-based approach to abrupt fault detection and diagnosis of sensors. *Instrumentation and Measurement, IEEE Transactions on*, 50(5), 1389-1396.