

DIAGNÓSTICO DE FALHAS EM SENSORES USANDO REDES NEURAIS: IMPLEMENTAÇÃO EM REDE INDUSTRIAL FOUNDATION FIELDBUS

Alexandre M. P. P. Filho*, Kennedy R. Lopes*, Victor L. C. M. da Silva*, Daniel L. Martins*, Adrião D. D. Neto*, Jorge D. de Melo*, Luiz A. Guedes*

*Laboratório de Sistemas Inteligentes
Departamento de Engenharia de Computação e Automação
Universidade Federal do Rio Grande do Norte
E-mails: [amppf, kenreurison, victor1706, danlartin, adriao, jdmelo, affonso]@dca.ufrn.br

Abstract – This work presents the study and implementation of intelligent algorithms for estimation of values in the natural gas measurement process, with the intention of detect possible failures in the sensors involved in these product custody transfer process. In the creation of these intelligent algorithms, were tested some recurrent neural networks architectures, due to some characteristics, like learning, adaptation and the capacity of capturing and dealing with a system dynamics. The recurrent neural networks were created to implement a predictor with the objective of reproduce the output dynamic behavior of the sensor, in such a way that the output of the network be compared to the output of the sensor, working as a basis for the detection and classification of failures that may occur in the device. The self organizing maps, however, were created to use the resulting values from the recurrent neural networks to diagnose the type of failure is occurring in the sensor, comparing the sensor value with the predictor value. Finally, this recurrent network was embedded in network of intelligent devices, called Foundation Fieldbus industrial network, obtaining then intelligent algorithms implemented in Field, noting that there are no reports of the implementation of recurrent neural networks in Foundation Fieldbus networks. It will be presented the prediction algorithms, how the neural networks were embedded in the Foundation Fieldbus Network and the results obtained in the tests.

Keywords – Fieldbus, Fault Detection, Fault Diagnosis, Recurrent Neural Networks, Self-Organizing Maps.

Resumo – Este trabalho apresenta o estudo e implementação de algoritmos inteligentes para estimação de valores no processo de medição de gás natural, com a finalidade de detectar possíveis falhas nos sensores envolvidos nos processos de transferência de custódia do produto, além de fazer a classificação das falhas detectadas a fim de tomar alguma decisão do modo mais rápido possível. Na criação destes algoritmos inteligentes, foram testadas algumas arquiteturas de redes neurais artificiais recorrentes para a predição e mapas auto-organizáveis para a classificação das falhas. As redes neurais recorrentes foram criadas para implementar um preditor com a finalidade de reproduzir o comportamento dinâmico da saída do sensor, o qual é comparado ao comportamento real do instrumento, formando assim a base para a detecção e classificação de falhas que possam ocorrer no dispositivo. Já os mapas auto-organizáveis foram criados com o intuito de utilizar o valor resultante das redes neurais recorrentes para diagnosticar qual tipo de falha está ocorrendo no sensor, comparando a saída do sensor com a saída do preditor. Finalmente, essas redes neurais foram embarcadas em uma rede de dispositivos inteligentes, chamada rede industrial Foundation Fieldbus, obtendo assim algoritmos inteligentes implementados em campo, ressaltando que não existem relatos da implementação de redes neurais recorrentes nem de mapas auto-organizáveis em redes Foundation Fieldbus. Serão apresentados os algoritmos de predição, o modo como as redes neurais foram embarcadas na rede Foundation Fieldbus e os resultados obtidos com os testes.

Palavras-chave – Fieldbus Foundation Fieldbus, Detecção de Falhas, Diagnóstico de falhas, Redes Neurais Recorrentes, Mapas Auto-Organizáveis.

1 Introdução

Com o advento da automação industrial, 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 seja possível 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. Em outras palavras, um sistema que possui um comportamento tolerante a falhas deve ser capaz de detectar e classificar automaticamente as falhas ocorridas, bem como ser capaz de continuar funcionando após as suas ocorrências. Todo este processo pode ser também definido como Detecção e Diagnóstico de Falhas (DDF).

Alguns métodos de detecção e diagnóstico de falhas são baseados na redundância física, ou seja, na duplicação de componentes de hardware, onde a principal desvantagem desses métodos é a necessidade de equipamentos extras, o que pode tornar o custo de manutenção bastante elevado, além de requerer um maior espaço físico para suas acomodações.

Outras técnicas, surgidas a partir da década de 70, 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 [1]. Uma das dificuldades desta abordagem é a necessidade da existência de um modelo matemático bem próximo da realidade.

Nos últimos anos, as pesquisas feitas no contexto dos Sistemas de Detecção e Diagnóstico de Falhas apresentam abordagens que utilizam os conceitos da Inteligência Artificial (IA), como por exemplo, Lógica Fuzzy [2] ou Redes Neurais Artificiais (RNA's) [3], de modo a evitar a utilização de modelos matemáticos explícitos.

Esse trabalho tem como objetivo realizar a predição do valor de saída de um sensor de temperatura de gás natural, de modo a garantir uma medição exata no processo de custódia do mesmo [4]. Essa predição deverá gerar informação suficiente para que seja possível a detecção de falhas, bem como fazer a classificação das mesmas, de modo que seja possível tomar a atitude correta para corrigir a falha o mais rápido possível. A predição será realizada por meio da utilização de redes neurais recorrentes, que permitem realizar a predição utilizando apenas valores da série temporal que se deseja simular, sem a necessidade de equações que descrevam o problema.

Já a classificação, será feita com mapas auto-organizáveis, que com treinamento não supervisionado, identifica diferentes defeitos que possam ocorrer na medição dos sensores. O sistema recebe como parâmetro dos sensores os valores medidos e os valores preditos por uma rede neural recorrente, também desenvolvida no projeto de pesquisa.

Essas redes neurais serão distribuídas e embarcadas em uma rede de sensores e atuadores com capacidade de processamento chamada rede Foundation Fieldbus, que pode ser instalada em campo e diminui a necessidade de um elemento supervisor, podendo tomar decisões de forma local, com base nos valores medidos. Uma das contribuições deste trabalho é que até o momento não existem relatos na literatura mostrando a implementação de redes neurais recorrentes em redes Foundation Fieldbus utilizando somente blocos funcionais padrão.

2 Foundation Fieldbus

A Fieldbus Foundation [5] é uma organização independente sem fins lucrativos com o propósito de desenvolver e manter um padrão internacional de redes de campo para automação de processos, o Foundation Fieldbus.

A rede Foundation Fieldbus é um sistema de comunicação digital, serial e bidirecional que funciona como uma rede local para instrumentos usados em processos e automação industrial, com capacidade para distribuir o controle da aplicação entre os dispositivos, já que os mesmos possuem microprocessadores e memória com várias funções, como operadores aritméticos e até mesmo controladores PID. Ela também pode ser interligada a redes Ethernet através de uma bridge, que faz o controle do fluxo de informações e dados entre as duas redes, com o intuito de configuração remota dos dispositivos. Uma de suas principais características é a organização da camada de aplicação em blocos, que por ser aberta e completamente especificada permite atingir um dos principais objetivos da fundação, a interoperabilidade.

Cada bloco funcional pode ser visto como um bloco de software que exerce processamento de sinais, deixando transparente para o usuário os detalhes internos de implementação. Esse encapsulamento possibilita o desenvolvimento descentralizado e independente de novos blocos funcionais, o que torna simples a tarefa de suprir a rede com novas funcionalidades. Outra vantagem dessa arquitetura é a possibilidade de se interligarem os blocos para que possam ser realizadas funções mais complexas, como a rede neural recorrente vista neste trabalho.

3 Diagnóstico Usando Redes Neurais

Uma rede neural pode ser usada para reproduzir o comportamento do sistema a ser monitorado de modo a gerar um vetor de erros cujos valores indicam a presença ou ausência de falhas, ou fornecer informações a um classificador. Para isso, a rede pode ser treinada com um conjunto entrada/saída que representa o sistema sob condições normais. No entanto, a entrada de um sensor é o mensurando que é desconhecido, pois os sensores são utilizados para converter grandezas que não podem ser explicitamente convertidas em parâmetros mensuráveis. Desta forma, a informação obtida do sensor é limitada à sua saída. Em vista disso, ao invés do conjunto entrada/saída, comumente usado em identificação de sistema, este trabalho propõe um mecanismo capaz de reproduzir o comportamento do sensor utilizando apenas o conjunto de saídas, em uma abordagem de predição [6].

O algoritmo de predição proposto é uma ferramenta poderosa capaz de fornecer estimativas confiáveis da saída do sensor monitorado em cada instante de tempo. Através do erro de predição, é possível detectar falhas, como citado anteriormente, caso este erro ultrapasse um limiar pré-estabelecido.

Detectar uma falha em um sensor significa indicar que o mesmo está em mau funcionamento, mas, determinar a causa do problema é uma atividade que requer uma análise mais detalhada do comportamento do sinal gerado pelo sensor. As arquiteturas de rede auto-organizadas têm a característica de associar padrões de entrada a agrupamentos, sem a necessidade de informação prévia sobre as tendências de sinal para cada padrão de falha ou sobre respostas esperadas para cada padrão. Por esta razão optou-se por investigar as potencialidades destas arquiteturas na classificação de falhas.

3.1 – Preditor Neural

Existem várias formas de realizar a predição de valores futuros em séries temporais, nesse trabalho foi utilizada uma rede NARX para realizar essa tarefa. A entrada da rede NARX é formada por duas janelas deslizantes (sliding time window), uma que desliza sobre o sinal de entrada e outra que desliza sobre o sinal de saída.

Dada uma série temporal, $\{x(n)\}$, $n=1:N$, define-se o regressor de entrada $U(n)$ da rede NARX como [7]:

$$U(n) = [u(n), u(n-1), \dots, u(n-du + 1)],$$

$$U(n) = [x(n), x(n-\tau), \dots, x(n-(dE-1)\tau)],$$

Onde o regressor $U(n)$ é composto de dE valores observados da série a cada τ instantes de tempo. Para levar em conta a informação dinâmica fornecida pelo laço de realimentação, a rede NARX pode ser treinada nos modos paralelo e série-paralelo.

No modo paralelo, o regressor do sinal de saída $Y(n)$ é definido como:

$$Y(n-1) = [y(n-1), y(n-2), \dots, y(n-dy)],$$

Onde $Y(n)$ compreende dy saídas anteriores da rede neural. É importante notar que, para uma rede treinada adequadamente, a saída da rede no instante n é uma estimativa do valor futuro da série, ou seja, $y(n) = y(n+1)$.

Já no modo série-paralelo (ou não-recorrente), o regressor de saída é definido da seguinte maneira:

$$Y(n-1) = [x(n), x(n-1), \dots, x(n-dy + 1)].$$

Sendo então construído com amostras reais da série temporal de interesse. Qualquer que seja o modo de uso da rede NARX, ambas as arquiteturas implementam o seguinte mapeamento entrada-saída:

$$Y(n) = y(n+1) = [Y(n-1), U(n)],$$

Em que a função não-linear (\bullet) pode ser realizada pela rede perceptron de múltiplas camadas padrão e treinada pelo algoritmo backpropagation simples.

3.2 Classificador Neural

O classificador neural utilizado neste trabalho foi o mapa SOM. Nesta rede neural, o treinamento funciona de maneira a incorporar o reconhecimento de padrões apresentados à rede de maneira auto-organizada. O mapa SOM classifica os padrões através da formação de um mapa topológico, onde a localização espacial de um neurônio de saída em no mapa corresponde a um domínio ou característica particular do dado retirado do espaço de entrada.

A rede possui duas camadas. A primeira é a camada de entrada, em que os dados são apresentados para a classificação dos padrões. A segunda camada indica qual padrão foi identificado através do neurônio ativado.

O treinamento ocorre em três processos: O processo competitivo, onde todos os neurônios calculam o seu valor de saída para determinar o neurônio vencedor. Este processo realiza-se através de uma função discriminante e o dado de entrada dado como parâmetro a cada neurônio. O processo cooperativo que realiza a atualização dos pesos sinápticos do neurônio vencedor como também em menor intensidade a modificação dos pesos sinápticos dos neurônios vizinhos. O último é o processo adaptativo. Neste processo os ajustes são realizados diretamente no neurônio vencedor de uma entrada para melhorar a resposta quando outra o mesmo padrão for apresentado.

4 Implementação na Rede Foundation Fieldbus

4.1 Construção de um Neurônio Artificial

Para a construção de uma rede neural, são necessários vários neurônios artificiais interligados, formando a arquitetura desejada. Como não existe um bloco funcional padrão com a finalidade de implementar um neurônio no ambiente Foundation Fieldbus, foi necessário desenvolver a rede neural utilizando apenas blocos funcionais padrões existentes [8].

Para implementar a rede neural no ambiente FF, foram utilizados dois tipos de blocos funcionais: blocos aritméticos e blocos caracterizadores de sinal (SCHAR), necessários para implementar a função tangente sigmóide. O bloco SCHAR, que possui 20 pares de pontos x e y e faz a interpolação dos mesmos, foi configurado com o objetivo de mapear a tangente sigmóide no intervalo requerido de modo bastante aproximado. Para melhor sintonizar os blocos caracterizadores, foi utilizada uma técnica de inteligência artificial chamada algoritmos genéticos.

Já para implementar o neurônio artificial, foram utilizados blocos aritméticos para aplicar os pesos e bias aos valores de entrada, definindo o parâmetro "algorithm type" como somador tradicional, que multiplica cada entrada por um peso e faz a soma desses produtos com um valor de bias. As saídas dos blocos aritméticos são então ligados às entradas dos blocos SCHAR para calcular a função de ativação.

4.2 Implementação da Rede Recorrente

Por meio de alguns testes e do estudo do funcionamento da rede Foundation Fieldbus, foi observado que a rede realiza primeiro o processamento de todos os blocos funcionais de um determinado instrumento, para só depois realizar o processamento dos blocos de outro instrumento. Desse modo, é possível gerar atrasadores alocando blocos funcionais em instrumentos diferentes, configurando a estratégia de controle de forma que cada vez que um dado é transmitido de um instrumento para outro, esse dado chega um instante de tempo atrasado em relação a um dado transmitido entre blocos alocados em um mesmo instrumento. Um exemplo de teste será descrito a seguir.




Figura 4.1 – Exemplo de teste para ilustrar o comportamento do atraso

No teste teste realizado, foram utilizados quatro blocos funcionais, sendo eles: IF1-ARTH1 e IF2-ARTH2 localizados no instrumento IF1, o IF2-ARTH1 localizado no instrumento IF2 e o bloco IF3-ARTH1 localizado no instrumento IF3.

O bloco IF1-ARTH1 tem valor inicial de saída igual a zero, tendo esse valor incrementado com o passar do tempo, por meio de realimentação. Esse valor de saída é repassado para os blocos IF1-ARTH2 e IF2-ARTH1. Feito isso, outro bloco funcional, o IF3-ARTH1 (alocado no instrumento IF3), recebe os valores de saída dos blocos IF1-ARTH2 e IF2-ARTH1 e subtrai o valor do primeiro pelo do segundo. A figura 4.3 ilustra uma linha do tempo com o valor de saída dos blocos funcionais utilizados.




Figura 4.2 – Saída dos blocos funcionais

Como o resultado dessa subtração é sempre igual a 1, conclui-se que a saída do bloco IF1-ARTH1 chega ao bloco IF2-ARTH1 um instante de tempo depois do bloco IF1-ARTH2. Esse teste foi repetido gerando-se vários atrasadores, com dados sendo repassados a diferentes blocos funcionais, gerando atrasos cada vez maiores, sempre obtendo o resultado esperado. De posse do resultado dos testes, pode-se perceber que é possível projetar os bancos atrasadores de modo a obter os atrasos desejados, sendo necessário apenas aumentar o número de blocos funcionais, alocando-os em diferentes instrumentos, de acordo com a necessidade.

Tendo visto como implementar um neurônio artificial e os bancos atrasadores, foi possível implementar a rede recorrente NARX, com 2 atrasos na entrada e 3 na saída, além de 1 camada oculta com 3 neurônios e função de ativação tangente sigmóide, e 1 neurônio na camada de saída. Deve-se considerar também que como a rede está distribuída por vários instrumentos diferentes, a informação demora certo tempo para ser recebida na entrada, processada e disponibilizada na saída, a rede deve ser treinada levando em conta esse atraso adicional. Fazendo um teste similar ao teste para verificar os atrasos em instrumentos diferentes, modificando os blocos funcionais de modo a simplesmente passar o valor recebido adiante, foi constatado que a saída referente a uma entrada disponibilizada no tempo t só vai ser retornada no instante $t+2$, com isso, foi treinada a rede NARX com as entradas x , $x-1$ e $x-2$, e as saídas $y-3$, $y-4$ e $y-5$. Um esquema de um neurônio da rede neural embarcada na rede Foundation Fieldbus será mostrado na figura 4.3.

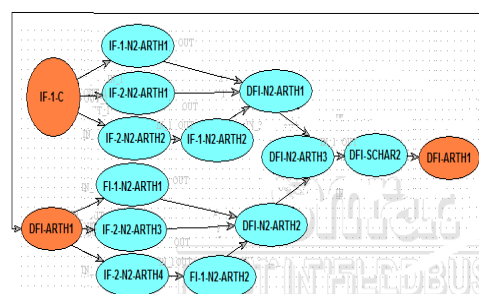


Figura 4.3 – Esquema de um neurônio da rede NARX implementada na rede FF

Na qual os blocos cor de laranja possuem os valores de entrada e saída da rede e os blocos azuis implementam o segundo neurônio da rede recorrente. Pode-se ver que no esquema que o bloco funcional IF-2-N2-ARTH1 é responsável por gerar um atraso na camada de entrada e os blocos funcionais IF-2-N1-ARTH2 e IF-1-N1-ARTH2 em conjunto geram dois atrasos nessa camada.

4.3. Implementação da Rede SOM

A implementação do mapa SOM foi idealizado para um modelo de 9 neurônios numa grade bidimensional. Os neurônios têm nas entradas os valores da variação real $\Delta y(n)$ e da variação predita $\Delta y_{pred}(n)$. A rede implementada nos instrumentos Foundation Fieldbus está esquematizada na figura FIGURA_1. No mapa SOM da figura, os blocos em azul correspondem as duas entradas da rede. Os blocos verdes são os nove neurônios que competem para determinação da melhor saída. Os pesos destes neurônios foram ajustados configurando o valor GAIN de cada bloco. Cada neurônio faz a ponderação das entradas e apresenta uma saída disponível para a rede. A saída geral da rede será definida pelo índice da melhor saída caracterizada pelo neurônio que possuir a maior resposta ao estímulo de entrada. Os blocos ISEL (em verde na figura Figura 4.4) não são conclusivos em determinar, como uma única saída, o neurônio vencedor. Por isso, foi utilizada uma rede MLP para calcular a camada competitiva do mapa auto-organizável.

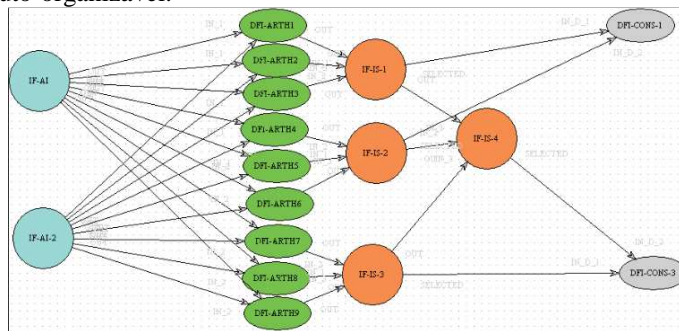


Figura 4.4 - Rede SOM implementada na rede industrial FF

O bloco ISEL possui somente três entradas e a saída são dois valores: a seleção do índice da maior entrada e o maior valor de entrada. Para Seria ideal que existisse um ISEL com 9 entradas, mas como esse não é um bloco padrão fornecido pelo padrão FF, foi definido um novo procedimento para o cálculo. O cálculo é um mapeamento de 4 entradas em uma saída. Para tanto foi definido uma rede neural 4:1 que mapeia os padrões a uma saída desejada.

5 Testes e Resultados

No trabalho desenvolvido, um algoritmo de predição baseado em redes neurais recorrentes é utilizado para reproduzir o comportamento da medição de um sensor de temperatura de gás natural, através de medições adquiridas em instantes de tempo presente e passados. Os valores obtidos dessas medições foram utilizados para treinar as redes neurais e realizar os testes desejados.

5.1 Organização da Arquitetura e da Comunicação

Para a realização dos experimentos, dispõe-se de um laboratório didático composto por uma estação de configuração e supervisão, uma rede Ethernet, uma ponte (DFI-302), que faz a interligação entre as redes Ethernet e Foundation Fieldbus e desempenha o papel de mestre da rede FF, e oito dispositivos de campo, onde três deles foram utilizados para a implementação da rede recorrente. Para fazer a comunicação entre o Matlab e o Syscon (programa responsável pela configuração da rede FF), a fim de transmitir os dados da série temporal para os instrumentos e avaliar a resposta dos mesmos, foi utilizado um toolbox do Matlab, o "opctool", capaz de fazer a comunicação entre os dois softwares via OPC [7].

5.2 Treinamento e Avaliação das Redes Neurais Re-correntes no Matlab

O primeiro passo dos procedimentos experimentais foi treinar algumas redes neurais, variando a quantidade de passos adiante a serem previstos, utilizando redes neurais cujas arquiteturas contavam com três neurônios na camada oculta e um neurônio na camada de saída. Essa arquitetura foi escolhida, pois ela foi utilizada no trabalho escrito por [de Medeiros, 2009]. As redes tinham como função de ativação a tangente sigmóide.

Para o treinamento de redes neurais foi utilizado o algoritmo do Filtro de Kalman Estendido. Foi feita a previsão de 1 até 10 passos na série temporal, com o sinal sem falhas, sendo utilizados 499 pontos para o treinamento e 168 pontos para validação, totalizando então 667 pontos. Depois de terminados os treinamentos, foram feitas simulações com as redes treinadas. Pode-se ver o resultado das simulações nas figuras 6.1, 6.2 e 6.3. Como critério de avaliação, foi feito um cálculo de correlação cruzada entre os valores de saída do sensor e do preditor. Os resultados serão expostos a seguir.

Tabela 5.1 – Correlações

Passos adiante utilizados na predição	Correlação com o valor real	Passos adiante utilizados na predição	Correlação com o valor real
1	0.9826	6	0.7848
2	0.9621	7	0.7091
3	0.9314	8	0.6374
4	0.8875	9	0.5872
5	0.8387	10	0.4930

Pode-se ver pela tabela que a rede neural é capaz de realizar a predição com uma forte correlação com a saída desejada para até 5 passos adiante na série temporal. O segundo passo foi fazer a simulação das redes neurais com falhas simuladas. Foram simulados quatro tipos de falhas, definidas como:

Falha 1: Valor zero. $Y_f(n) = 0$.

Falha 2: Valor de Fundo de escala. $Y_f(n) = 60$.

Falha 3: Deriva de fator de escala. $Y_f(n) = Y(n)e^{-ak}$.

Falha 4: Deriva de Offset. $Y_f(n) = Y(n) - ak$.

Definidos os tipos de falhas a serem simuladas, foram feitos testes com cada tipo de falha, fazendo a predição de 1 e 2 passos adiante na série temporal. O resultado de um dos testes pode ser visto na figura 5.1.




Figura 5.1 – Preditor de 2 passos para uma série com a Falha 3

5.3 Embarcar a Rede Neural Recorrente na Rede Industrial

Depois feitos os testes, foi escolhida a rede neural com predição de 1 passo adiante, já que a mesma é mais estável e também apresenta um valor de saída diferente da saída do sensor quando o mesmo apresenta falhas.

Para que a rede neural previamente treinada seja embarcada no ambiente industrial, a rede Fieldbus foi configurada com os blocos funcionais de acordo com o esquema da figura 4.3. Depois que os instrumentos foram configurados, os pesos da rede neural foram exportados para a rede industrial para que os testes pudessem ser realizados. Os resultados de dois dos testes podem ser vistos na figura 5.3.





Figura 5.2 – Predição de 1 passo de uma série sem falhas e de uma série com falhas dos tipos 3 e 1, na rede FF

5.4 Treinamento e Avaliação das Redes SOM no Matlab

As falhas consideradas foram as mesmas indicadas na seção 5.2. Sendo elas, duas falhas abruptas (Falhas 1 e 2) e duas falhas incipientes (Falhas 2 e 3). Várias falhas podem ser derivadas desses dois tipos básicos. Estas falhas existem na maioria dos sensores. Uma análise mais detalhada pode ser desenvolvida para o diagnóstico utilizando o conhecimento dos tipos de problemas que um sensor específico pode apresentar. Neste trabalho, o mapa SOM foi desenvolvido para mapear os diferentes padrões existentes no erro de medição. Como o treinamento é auto-supervisionado, o problema pode ser generalizado para qualquer outro tipo de falha.

Os dados apresentados são definidos pela variação da entrada real e o a variação da entrada estimada com o último valor real. Espera-se então que a variação real apresente um resultado anômalo antes da variação estimada, caracterizando-se assim a existência de uma falha, como indica a figura 5.3.




Figura 5.3 – Padrão apresentado à rede SOM e percepção da falha através vista através do sensor

De acordo com os padrões existentes entre esses dois sinais a rede SOM foi treinada no Matlab para 15 sinais da série temporal da temperatura modificados de forma a possuir os quatro tipos de falhas em diferentes instantes de tempo.

5.5 Treinamento e Avaliação das Redes SOM na Rede Industrial

Depois de treinado as falhas no Matlab, os novos pesos dos neurônios foram ajustados para a rede Foundation Fieldbus instanciada. A figura 5.4 mostra o estado de ativação do neurônio 1 instanciado na rede industrial Foundation Fieldbus. Observe que no momento que surge a falha 2, o neurônio ativa-se automaticamente, permanecendo até o momento de fim de falha. Verificamos então que a ativação do neurônio 1 está intimamente relacionado com a presença da falha 2. Outro caso é a ativação do neurônio 9 quando ocorre a falha 1, visto na figura 5.5.

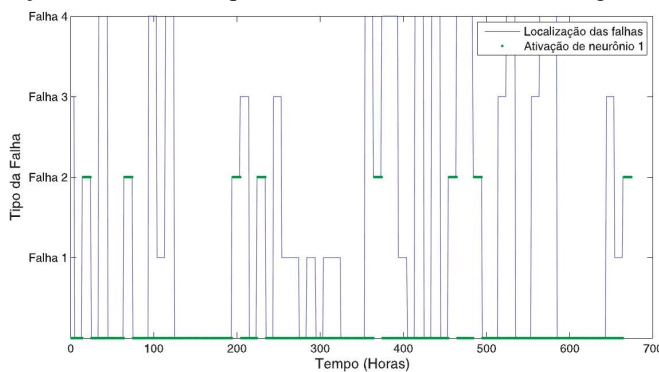


Figura 5.4 - Estado de ativação do neurônio 1 na presença da falha 2




Figura 5.5 - Estado de ativação do neurônio 9 na presença da falha 1

As falhas 1 e 2 pertencem a um padrão mais simples de se diagnosticar, enquanto que as falhas 3 e 4 são muito parecidas e não houve uma distinção completa de qual neurônio ativa na presença da falha 3 ou na falha 4. Isto ocorre devido à grande semelhança entre as falhas de deriva. Entretanto as falhas incipientes são diferenciadas das falhas abruptas que ocorrem no sensor. De acordo com a classificação da falha em função do neurônio ativado, a tabela_1 foi montada tabela relaciona o tipo de falha com a pelo mapa SOM. Na tabela 3 observamos que a classificação de F₃ em F₄ e F₄ em F₃ obteve o mesmo resultado de sua correta classificação. Este resultado se dá pelo motivo que as falhas 3 e 4 são diagnosticadas quando os mesmos neurônios são ativados.

Tabela 5.2 - Relação entre o tipo de falha e a classificação pelo mapa

Tipo/Classe	F ₁	F ₂	F ₃	F ₄
1	98.9%	1.1%	0%	0%
2	0%	100%	0%	0%
3	2.19%	1.86%	94.9	
4	2.03%	1.01%	93.13	

6 Conclusão

Neste trabalho, foram desenvolvidos algoritmos inteligentes com o objetivo de diagnosticar falhas em um sensor de temperatura de gás natural. Foram utilizadas redes neurais recorrentes, de modo a fazer a predição dos valores de saída do sensor, onde o valor retornado pelo preditor pode ser comparado à saída real do sensor, de modo que, caso a diferença entre os dois sinais de saída seja significativa, existe a possibilidade de ocorrência de uma falha no sensor. Além de ser usada para detecção de falhas, a diferença entre os valores de saída do preditor e do sensor pode ser utilizada para a classificação de falhas, que foi feita utilizando uma rede neural auto-supervisionada do tipo SOM. Isso foi possível pois as diferentes falhas geram comportamentos diferentes no sensor e no preditor.

Além de serem implementadas no computador, as redes neurais foram embarcadas em uma rede industrial Foundation Fieldbus, que é uma rede de instrumentos com capacidade de processamento instalados em campo, que funcionam de modo paralelo e não necessitam de um elemento centralizador para que a tomada de decisões seja feita. Deve-se ressaltar a importância desse trabalho, já que não existem na literatura implementações de redes neurais recorrentes em redes industriais Foundation Fieldbus utilizando somente blocos funcionais padrão.

Foram feitos testes com algumas estratégias diferentes de predição e diversas falhas simuladas, onde foram obtidos resultados satisfatórios, que demonstraram que as redes neurais podem realizar as funções de preditor de séries temporais e de classificador de falhas, assim como foi visto que é possível embarcar redes neurais recorrentes no ambiente industrial Foundation Fieldbus.

Algumas sugestões para trabalhos futuros são o estudo mais aprofundado e melhoria do processo de simulação de falhas, gerando mais tipos de falhas simuladas e a aplicação desse trabalho na criação de sensores de software aplicados à produção de derivados de petróleo, utilizando o software Hysys para simular os processos estudados e a rede FF para realizar as operações com instrumentos reais.

Agradecimentos

Os autores gostariam de agradecer à ANP que através do PRH-14 apoiou a realização deste projeto, bem como a Petrobrás, a Redic e a Finep pelos recursos disponibilizados para o projeto.

Referências Bibliográficas

- [1] Persin, S., B. Tovornik, N. Muskinja & D. Valh (2002), Increasing process safety using analytical redundancy, em 'Electrotechnical Review', pp. 240–246.
- [2] Uppal, Faisal J., Ron J. Patton & Marcin Witczak (2005), A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the damadics benchmark problem, em 'Control Engineering Practice'.
- [3] de Medeiros, J. P (2009), 'Estudo e Implementação de Algoritmos Inteligentes para Detecção e Classificação de Falhas na Medição de Gás Natural', Dissertação de mestrado, Universidade Federal do Rio Grande do Norte.
- [4] Rodrigues, B (2004), 'Gasoduto Virtual. Uma Alternativa para Expansão do Uso do Gás Natural', monografia de conclusão de curso de Administração de Empresas, Universidade Paulista.
- [5] Lima, F. S, Guedes, L. A., Salazar, A. O, Maitelli, A. L (2004), Hybrid Environment for Tests and Training in Fieldbuses, 'VI Induscon 2004', Joinville, SC.
- [6] Haykin, S (2005), 'Neural Networks. A Comprehensive Foundation'.
- [7] Júnior, J. M. P. M (2006), 'Redes Neurais Dinâmicas para Predição e Modelagem não-linear de séries temporais', Dissertação de mestrado, Universidade Federal do Ceará.
- [8] Silva, D. R. C (2005), 'Redes Neurais Artificiais no Ambiente de Redes Industriais Foundation Fieldbus Usando Blocos Funcionais Padrões', Dissertação de mestrado, Universidade Federal do Rio Grande do Norte.
- [9] Carvalho, A. S., Silva, R. C. and Nascimento, D. B (2009). Sistema de Comunicação OPC para uma Coluna de Destilação Piloto, 'Simpósio de Excelência em Gestão e Tecnologia', Resende, RJ.