

Monografia de Graduação

Implementação de classificador neural no ambiente Foundation Fieldbus

Kennedy Reurison Lopes

Natal, dezembro de 2009



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE COMPUTAÇÃO E
AUTOMAÇÃO



Trabalho de Conclusão de Curso apresentado à banca examinadora composta pelos seguintes membros:

Prof. Dr. Jorge Dantas de Melo (Orientador) DCA/UFRN

Prof. Dr. Adrião Duarte Dória Neto (Co-orientador) DCA/UFRN

M. Sc. Leonardo Sávio Guanabara Ramalho DCA/UFRN

*Dedico este trabalho a minha mãe,
Ana Cleide Alves de Araújo Lopes.*

Agradecimentos

Aos meus professores orientadores Jorge Dantas de Melo e Adrião Duarte Dória Neto, sou grato pela orientação e pelo seu reconhecimento.

Aos meus pais João Batista e Ana Cleide pelo apoio e educação e às minhas irmãs Amanda e Kallinny pelo incentivo.

À toda minha família pelo apoio durante esta jornada.

Aos amigos do LAUT, DCA e PoP-RN.

À todos os meus amigos, pelo incentivo para que eu seguisse em frente sem desanimar.

À ANP, pelo apoio financeiro.

Resumo

Este trabalho de conclusão de curso apresenta o estudo da implementação de algoritmos inteligentes embarcados na rede industrial Foundation Fieldbus para o diagnóstico de falhas em sensores envolvidos na transferência de custódia de gás natural. O algoritmo consiste em classificar falhas que possam existir em um sensor, considerando os tipos de falhas que podem ocorrer. Uma rede auto-organizável (SOM) foi implementada para que a partir treinamento da dinâmica do sensor com a predição de passos múltiplos de uma rede recorrente verifique-se a presença de uma falha e consiga diagnosticá-la.

Palavras-chave: Redes Neurais Artificiais, Mapa Auto-organizável, rede *Foundation Fieldbus*, Sensores Inteligentes, diagnóstico de falhas.

Abstract

This graduation conclusion monograph presents the implementation of intelligent algorithms embedded in the Foundation Fieldbus industrial network for faults diagnosis in sensor involved in natural gas custody transfer. The algorithm is to classify a fault that occurs on a sensor, considering the types of failures that may happen. A self-organizing map (SOM) was implemented so that, from training the dynamics of the sensor with the dynamics of a recurrent network to predict multiple steps to verify the presence of a failure and can diagnose it.

keyword: Artificial Neural Networks, Self-organizing Maps, network *Foundation Fieldbus*, Smart sensors, fault diagnosis.

Sumário

Sumário	i
Lista de Figuras	iii
Lista de Tabelas	iv
Lista de Símbolos e Abreviaturas	v
1 Introdução	1
1.1 Introdução	1
1.2 Motivação	2
1.3 Objetivos	2
1.4 Organização do texto	3
2 Redes Neurais Artificiais	4
2.1 Introdução	4
2.2 Modelo de neurônio artificial	5
2.3 Rede perceptron de múltiplas camadas - MLP	7
2.4 Mapas auto-organizáveis	9
2.5 Diagnóstico de falhas em sensores	10
2.5.1 Redes Neurais Artificiais	11
3 Sensores Inteligentes na Rede Foundation Fieldbus	13
3.1 Introdução	13
3.2 Rede <i>Foundation Fieldbus</i>	13
3.2.1 Arquitetura da rede industrial	14
3.2.2 Blocos funcionais	15
3.3 Sensores inteligentes	17
4 Metodologia	19
4.1 Introdução	19

4.2	Algoritmo para diagnóstico de falhas	19
4.3	Procedimentos	21
4.4	Mapa SOM	22
5	Resultados	25
6	Considerações Finais	30

Lista de Figuras

2.1	Modelo de um neurônio	6
2.2	Rede de múltiplas camadas	8
2.3	Grade Bidimensional de neurônios	9
3.1	Comunicação em camadas do sistema OSI e do Fieldbus	15
3.2	Bloco funcional Aritmético	16
3.3	Bloco caracterizador de sinais	17
3.4	Bloco seletor de entrada	17
3.5	Neurônio artificial implementado através de blocos funcionais	18
3.6	Neurônio artificial com 6 entradas implementado através de blocos funcionais	18
4.1	Esquema de diagnóstico de falhas	20
4.2	Esquema de diagnóstico de falhas	21
4.3	Quatro falhas simuladas	22
4.4	Predição de 2 passos	22
4.5	Neurônios da rede SOM	23
5.1	Percepção da falha vista pelo sensor e pelo preditor	26
5.2	Estado de funcionamento do sensor	26
5.3	Estado de ativação do neurônio 1 na presença da falha 2	27
5.4	Estado de ativação do neurônio 9 na presença da falha 1	27
5.5	Estado de ativação do neurônio 3 na presença da falha 1	28

Lista de Tabelas

4.1	Parâmetros para o mapa SOM	23
4.2	Exemplos de padrões mapeados para determinação do neurônio vencedor	24
5.1	Classificação da falha em função do neurônio ativado	28
5.2	Mapa de confusão	29

Lista de Símbolos e Abreviaturas

ARITH	Bloco Funcional Aritmético
CLP	Controlador Lógico Programável
FF	Foundation Fieldbus
ISEL	Bloco Funcional Seletor de Entrada
MLP	Rede de Múltiplas Camadas
NARX	Nonlinear AutoRegressive model with eXogenous input
OPC	<i>OLE for process control</i>
OSI	Open Systems Interconnection
SCHAR	Bloco Funcional Condicionador de Função
SOM	Self-organizing map (Mapas auto-organizáveis)

Capítulo 1

Introdução

1.1 Introdução

O gás natural é um produto que deve ser monitorado constantemente, desde a etapa de produção até a etapa de comercialização e distribuição. A distribuição é realizada pela custódia de diferentes empresas e a transferência é realizada sob padrões rigorosos de medições específicas nos entroncamentos de gasodutos ou em *citygates*. Devido às enormes quantidades de gás transportadas pelos gasodutos é muito importante que existam sensores confiáveis para medição das características desse gás natural, pois pequenos erros de medição provocam grandes prejuízos às empresas envolvidas [CTGÁS 2007].

Desta forma, os instrumentos de medição devem estar corretamente calibrados para que não haja imprecisão dos valores medidos. Qualquer falha que ocorrer nos sensores deverá ser relatada e diagnosticada imediatamente.

A proposta de classificação de erros em sensores planeja o desenvolvimento de mapa auto-organizável que, com treinamento não supervisionado, identifique diferentes defeitos que possam ocorrer nas medições dos sensores. Para isso, basta que o sistema desenvolvido receba como parâmetro os valores medidos pelo sensor e os valores preditos por uma rede neural recorrente.

O sistema previamente treinado com os dados preditos pela rede neural *NARX* deverá ser *embarcado* na rede industrial *Foundation Fieldbus* (FF). A inclusão do mapa auto-organizável será realizado através da devida configuração dos blocos funcionais padrão FF de acordo com os resultados do treinamento do *SOM*. Depois de configurados, os instrumentos *FF* indicarão automaticamente o tipo de erro de leitura sem a necessidade da supervisão de um operador.

1.2 Motivação

A capacidade da realização de cálculos na rede Foundation Fieldbus é o principal motivo para a implementação de algoritmos e procedimentos que auxiliem os processos industriais. Os sensores de medição podem ser acoplados à rede *Foundation Fieldbus*, permitindo a realização de estratégias de controle e diagnósticos de erros. Com isso, a rede ganha liberdade para realizar tarefas rotineiras tradicionalmente efetuadas dentro de um sistema supervisório e que agora podem ser feitos diretamente nos instrumentos de campo.

O poder de processamento dos instrumentos que o FF proporciona é útil para realização de detecção de erros, predição de falhas nos sensores, identificação do tipo de erro atuante na planta, construção de controladores tradicionais como PID e até de controladores avançados como controlador *Neural* e *Fuzzy*. O aproveitamento de instrumentos de medição para realização de cálculos é de interesse no presente trabalho. Os procedimentos adotados exploram a capacidade da rede na realização dos cálculos para classificação de erros.

A flexibilidade na construção do projeto da rede e a simplicidade da realização de cálculos garante uma redução de custos para a construção do sistema de controle, pois as análises serão feitas nos próprios dispositivos. Devidamente configurados, os instrumentos passam a identificar o erro de medição através de processamento local e distribuído por toda a rede nos dispositivos FF.

1.3 Objetivos

O treinamento é feito de forma não supervisionada, o que proporciona uma flexibilidade na classificação de erros. Com isso, os erros não precisam de uma prévia classificação para serem apresentados a rede neural no momento do treinamento. A rede que irá construir um mapa auto-organizável para identificar os padrões existentes no conjunto de dados apresentados. Feito isto a classificação fica automática.

Em geral, as técnicas de detecção e diagnóstico de falhas se baseiam na implantação de modelos matemáticos que tentam reproduzir o que o sensor deveria estar medindo ou através de análises de sinais. Ambas estratégias necessitam de um alto processamento e têm custo elevado.

O principal objetivo é mostrar que é possível a implementação do mapa SOM para classificar falhas em sensores sem a intervenção, ou supervisão humana. Promovendo desta forma uma autonomia aos sensores para realização de cálculos e reduzindo a comu-

nicação entre instrumentos e supervisórios.

1.4 Organização do texto

O capítulo 2 aborda o assunto de Redes Neurais Artificiais. O capítulo é destinado a fundamentação teórica do assunto, apresentando dois modelos de rede neural utilizados no trabalho e alguns conceitos de redes neurais. O capítulo 3 apresenta os conceitos relativos a rede *Foundation Fieldbus* como Blocos Funcionais e como é realizado a interconexão destes blocos para construção de sensores inteligentes dentro dos instrumentos de campo. A metodologia abordada está explicada no capítulo 4 e os resultados no capítulo 5. As considerações finais e perspectivas futuras estão no capítulo 6.

Capítulo 2

Redes Neurais Artificias

2.1 Introdução

Uma rede neural artificial é um sistema não-linear e paralelo inspirado no modelo biológico do funcionamento dos neurônios e suas conexões. As redes neurais são células de processamentos conectadas por ligações sinápticas e possuem a característica de armazenar informação, disponibilizando para uso.

O cérebro é capaz de armazenar o conhecimento e realizar certos processamentos de uma maneira bem mais rápida que o mais moderno computador digital hoje existente. Por exemplo, é capaz de filtrar as informações mais relevantes do que existe ao nosso redor para que possamos interagir com o ambiente. Tarefas ainda mais simples do que essa pode levar dias para serem executadas por um computador convencional.

Apesar do modelo computacional não reproduzir os procedimentos de aprendizagem de um cérebro humano, podemos destacar características e utilidades que são atualmente exploradas nas redes neurais artificiais:

- Não-linearidade: A rede neural pode ser não-linear, basta que a rede possua conexões com neurônios não lineares.
- Mapeamento de entrada-saída: O mapeamento de entrada e saída permite que a rede funcione como um gerador de função genérica. Desta forma a rede funciona como um classificador universal e através de um conjunto de padrões aprende como determinar a saída em função de uma entrada não apresentada no treinamento.
- Adaptabilidade: Uma rede neural pode desempenhar certa função e através de um re-treinamento realizar outra tarefa. Isto é permitido pela simplicidade do modelo. A função que a rede desempenha depende dos valores dos pesos sinápticos e, alterar seus valores, modificam sua funcionalidade. Desta forma podemos instanciar uma rede como uma controladora neural e reconfigurá-la para funcionar como um classificador de erros.

- Resposta a evidências: Como classificador de padrões, a RNA determina qual padrão corresponde a determinada entrada e o percentual de crença na decisão tomada.
- Informação textual: A ativação de um neurônio afeta o estado de ativação dos outros neurônios, como uma informação se propagando pela rede neural.
- Tolerância a falhas: A rede neural é robusta suficiente para suportar defeitos em algum neurônio, de modo que a rede mesmo perdendo em desempenho pode realizar suas tarefas satisfatoriamente [Haykin 2001].

2.2 Modelo de neurônio artificial

A rede neural artificial é um modelo computacional inspirado no sistema biológico do cérebro. Este modelo idealiza neurônios computacionais como "unidades de processamento" que são interligados por conexões sinápticas. Ligações que são caracterizadas pelos seus pesos. A figura 2.1 esquematiza o modelo de um neurônio em particular, com os seus seguintes componentes:

- Pesos sinápticos: Correspondem às forças de ligação entre neurônios e realizam a ponderação dos valores de entradas x_j . São definidos pelos seus pesos w_{kj} , relativos ao neurônio k e a ligação j do neurônio.
- Combinado linear: A entrada X é ponderada pelos pesos sinápticos e somados juntamente com o valor do bias b_k . Gerando campo local induzido v_k para a função de ativação.
- Função de ativação: Dependendo da função escolhida, o neurônio pode ser linear ou não-linear e a função limita o campo local induzido para $[0, 1]$ ou $[-1, 1]$.

Matematicamente, o neurônio é modelado pelas expressões 2.1 e 2.2.

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$y_k = \varphi(v_k + b_k) \quad (2.2)$$

onde x_1, x_2, \dots, x_m são as entradas; w_{kj} é o peso sináptico j do neurônio k ; b_k é o bias, u_k é a saída do combinador linear e y_k é o resultado final, depois de passar pela função de ativação $\varphi(\cdot)$. O bias é b_k , aplicado externamente e tem o efeito de aumentar ou diminuir a saída do combinador linear.

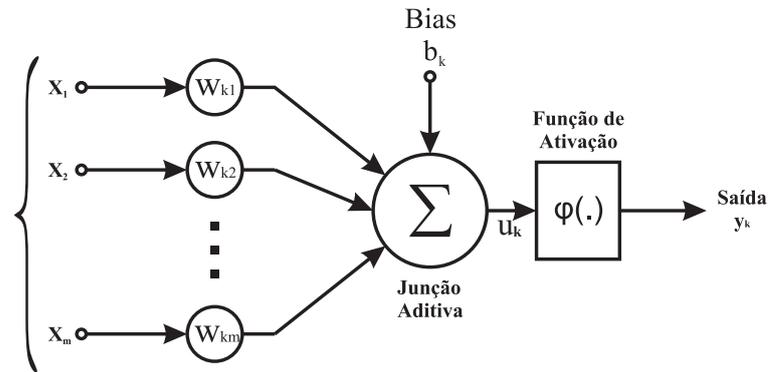


Figura 2.1: Modelo de um neurônio

A função de ativação define a saída do neurônio em termos do campo local induzido v . Os três tipos básicos de função de ativação são:

- Função de limiar: Possui o valor de 1 somente se v for maior ou igual a 0.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (2.3)$$

- Função Limiar por partes: Possui o valor de 1 somente no caso de v ultrapassar um certo limiar superior ou 0 se ultrapassar um limiar inferior. Caso não ultrapasse, a função possui um fator de amplificação da entrada v .

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq +\frac{1}{2} \\ v, & \text{se } +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (2.4)$$

- Função Sigmóide: É a função de ativação mais comum utilizada na construção de redes neurais. Ela possui a forma de um "s" e é uma função estritamente crescente. Possui um balanceamento adequado entre o compartimento linear e não-linear.

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.5)$$

As funções definidas em 2.3, 2.4 e 2.5 possuem saídas entre 0 e +1. Entretanto, algumas vezes é desejável que a saída possua valores entre -1 e $+1$. Como exemplo,

temos a função sinal, definida como

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (2.6)$$

Dependendo das ligações e dos tipos de neurônios utilizados, várias redes neurais podem ser concebidas. O posicionamento dos neurônios indica também que tipo de rede está sendo implementada e o algoritmo que deverá ser utilizado para treinamento.

De acordo com a colocação dos neurônios, a rede neural pode ser Perceptron, Perceptron de Múltiplas Camadas (MLP), rede Hopfield, mapa SOM, dentre outras. Em particular, a rede MLP se caracteriza por possuir camadas de entrada, saída e camadas ocultas de neurônios e o mapa SOM permite a criação de um mapa topológico para classificar um conjunto de padrões.

2.3 Rede perceptron de múltiplas camadas - MLP

Quando Redes Neurais Artificiais de uma só camada são utilizadas, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, ou seja, não é possível a formação de uma representação interna. Neste caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento.

Tal restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva o sistema à incapacidade de aprender importantes mapeamentos. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias. Um exemplo clássico deste caso é a função ou-exclusivo (XOR).

Contudo, o desenvolvimento do algoritmo de treinamento *backpropagation* mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizado atualmente, as redes Perceptron Multi-Camadas (MLP), treinadas com o algoritmo *backpropagation*.

Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie

sua própria representação, mais rica e complexa, do problema. Um exemplo da rede MLP está esquematizado na figura 2.2. Trata-se de uma rede com duas camadas intermediárias e uma camada de saída. Pode-se perceber que a rede é completamente conectada, de forma que qualquer neurônio das camadas ocultas está conectado com todos os neurônios da camada seguinte.

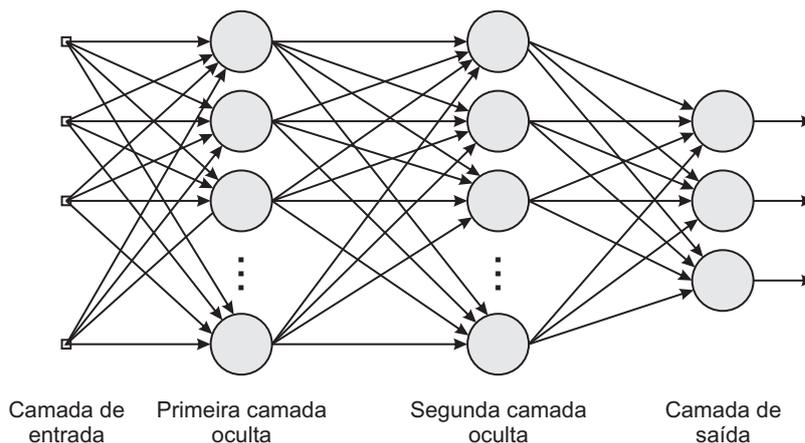


Figura 2.2: Rede de múltiplas camadas

Se existirem as conexões certas entre as unidades de entrada e um conjunto suficientemente grande de unidades intermediárias, pode-se sempre encontrar a representação que irá produzir o mapeamento correto da entrada para a saída através das unidades intermediárias. Com isso, a rede MLP funciona como um aproximador universal de funções, capaz de fornecer uma saída para cada padrão de entrada apresentado.

O treinamento é realizado em dois passos principais. No primeiro passo existe a propagação de um estímulo apresentado à rede. Os pesos sinápticos permanecem inalterados em toda a rede até chegarem a camada de saída. A resposta da camada de saída é apresentada à rede e comparada ao valor desejado para aquele estímulo apresentado. Desta forma, um sinal de erro surge para cada neurônio da camada de saída. O segundo passo consiste em retropropagar o sinal de erro. Assim o processo continua por passar o sinal para a esquerda calculando recursivamente o gradiente local de cada neurônio. Este processo permite que os pesos sinápticos sofram uma correção de acordo com a regra delta, apresentado em 2.7.

$$\Delta w_{ji} = \eta \delta_j(n) y_i(n) \quad (2.7)$$

2.4 Mapas auto-organizáveis

O mapa auto-organizável (SOM) é uma rede neural inspirada na analogia da região do córtex cerebral humano. Esta região do cérebro é caracterizada pela diminuição do grau de ativação dos neurônios em função do distanciamento da região de ativação. O estudo levou a formação de *mapas topográficos* que pode ser formulado como: A localização espacial de um neurônio de saída em um mapa topográfico corresponde a um domínio ou característica particular do dado retirado do espaço de entrada.

No mapa SOM, os neurônios são inicialmente colocados em um grid e interconectados por uma região de vizinhança, descrevendo a topologia do mapa, conforme é apresentado na figura 2.3. O grid normalmente é unidimensional ou bidimensional com disposição retangular ou hexagonal. Matematicamente, o mapa SOM é uma RNA com duas camadas: a camada de entrada I e a de saída U . A entrada corresponde a um vetor no espaço de d dimensões em \mathfrak{R}_d , representado por $x_k = \xi_1, \xi_2, \dots, \xi_d^T$, para $k = 1, 2, \dots, n$. Com n sendo o número de vetores de entrada. Cada neurônio j da camada de saída possui um vetor w também no espaço \mathfrak{R}_d , associado ao vetor x_k , $w_j = w_{j1}, w_{j2}, \dots, w_{jd}$.

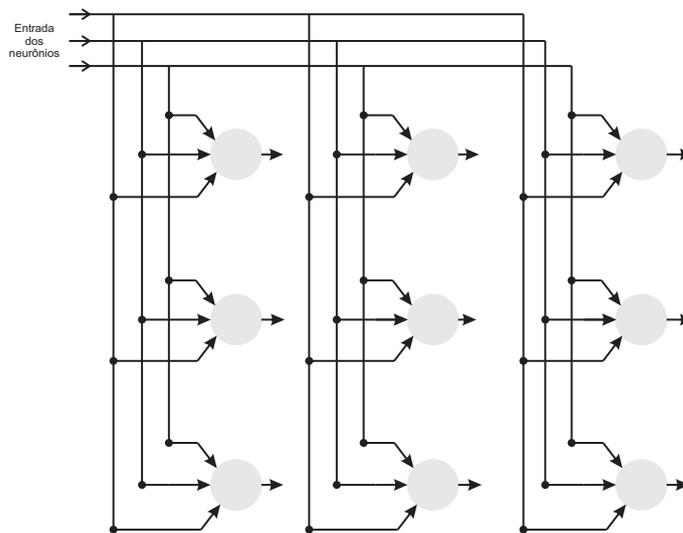


Figura 2.3: Grade Bidimensional de neurônios

Esta grade de neurônios é baseada na aprendizagem competitiva, de forma que apenas um neurônio da camada de saída estará ativado em cada instante de tempo. O neurônio ativado é chamado de *neurônio vencedor* e o pesos dos vizinhos são ajustados em função de sua distância ao neurônio vencedor. Conforme transcorre o treinamento, verificamos a existência de agrupamentos de neurônios que se tornam seletivamente aptos a determinados estímulos do padrão de entrada.

O processo de aprendizagem começa pela inicialização dos pesos sinápticos com valores pequenos e aleatórios. Desta forma, nenhuma organização prévia é imposta ao mapa. Depois de inicializada, a rede é treinada mediante 3 passos. Competição, cooperação e adaptação sináptica.

1. Processo competitivo:

Para cada padrão de entrada, os neurônios da grade calculam seus valores de uma função discriminante. Esta função é a base para a competição, de forma que o neurônio vencedor é aquele com o maior valor da função discriminante. O vetor x de dimensão m é aplicado à rede e o vetor peso sináptico w_j para cada neurônio j possui a mesma dimensão do vetor de entrada. Com a finalidade de descobrir o neurônio com a menor distância euclidiana do padrão de entrada, escolhe-se o neurônio com menor produto interno $w_j^T x$, dado pela equação 2.8.

$$i(x) = \operatorname{argmin} \| \|x(n) - w_j\| \|, j = 1, 2, \dots, l \quad (2.8)$$

2. Processo cooperativo:

O neurônio vencedor determina uma vizinhança topológica de neurônios excitados, fornecendo a base da cooperação entre neurônios. Inicialmente, a função $h_{j,i(x)(n)}$ deve incluir todos os neurônios da grade e ser diminuir lentamente com o transcorrer do treinamento.

3. Processo adaptativo:

Consiste em aumentar a função discriminante do neurônio vencedor i_j do padrão de entrada x_j . O ajuste é realizado diretamente nos pesos sinápticos do neurônio vencedor e tem o intuito de melhorar a resposta do neurônio quando for apresentado a mesma entrada [Haykin 2001].

2.5 Diagnóstico de falhas em sensores

A detecção e o diagnóstico da falha podem ser vista em três principais níveis: nível da planta, do processo e do próprio sensor. No nível da planta, de forma que um modelo do processo é utilizado para comparar com o valor medido pelo sensor. Quando a diferença entre o medido e o simulado ultrapassar certo limite, a falha é detectada e diagnosticada. No nível do processo são colocados sensores redundantes para efeito de comparação com o sensor em questão. No nível do sensor, o estado do funcionamento do instrumento é verificado a partir da análise de sua própria saída. O diagnóstico local é realizado neste trabalho. O próprio sensor informa seu estado de funcionamento e, caso ocorra uma

falha, relata o problema com uma informação mais precisa para que as devidas ações sejam tomadas.

As técnicas tradicionais utilizadas para detecção e diagnóstico de falhas se baseiam em redundâncias físicas ou analíticas. A redundância física é normalmente utilizada quando o processo não pode ser interrompido devido a problemas de segurança, custo de uma eventual troca de sensor, falta de tempo. Esta redundância é realizada colocando um sensor auxiliar em paralelo com a medição do sensor principal. Quando os valores medidos pelos sensores divergem suficientemente para se identificar uma falha, alternativamente o sensor auxiliar pode tomar o controle e continuar o processo de medição. A desvantagem dessa técnica é que o custo de implementação é alto, é necessário um espaço extra para alocar os instrumentos e há alta complexidade de *hardware* para incorporar tal sistema. Devido a estas desvantagens, pode ser mais viável utilizar uma redundância analítica.

A redundância analítica é realizada quando existe um modelo físico do processo monitorado. Desta forma, um processo é executado na planta real e outro é simulado em computador. O processo simulado visualiza a saída de medição de vários sensores. Os dados unificados são analisados e é feita uma inferência do valor de medição de um sensor para detecção de falha. Quando o modelo diverge muito do valor medido pela planta, dizemos que algum sensor apresenta falha. A partir disto pode-se diagnosticar o que está acontecendo e em qual sensor ocorre o erro. A dificuldade da técnica de redundância analítica está em desenvolver um modelo de entrada e saída para cada grandeza envolvida no processo e encontrar as relações funcionais entre os sensores com o objetivo de determinar qual sensor está com defeito e o que está ocorrendo. Ainda existem os erros de modelagem, pois os modelos expressam condições ideais de funcionamento e ruídos ou perturbações do processo são difíceis de modelar.

Outra técnica bastante utilizada é a análise do espectro de saída do sensor. Nesta técnica a análise da própria saída do sensor deve possuir informação suficiente para a descoberta da falha. A transformada *Wavelet* é adequada para a análise destes sinais, pois é eficiente para a análise do sinal no tempo e na frequência. Como desvantagem, tem-se as limitações relacionadas pela baixa resolução espectral em alta frequência e a latência na obtenção de informações relevantes em baixa frequência [Fernandes 2007].

2.5.1 Redes Neurais Artificiais

Devido à capacidade de aprender a partir de uma base de informações, uma rede neural pode adquirir conhecimento suficiente sobre o funcionamento de um sensor de tal forma que, na presença de falhas, seja possível identificar anomalias. Algumas características de

robustez e generalização das redes neurais fazem com que elas sejam uma ferramenta bastante utilizada para detecção e classificação de falhas mesmo sobre a presença de ruídos [Haykin 2001]. Desta forma, a RNA tem a vantagem de ser robusta o suficiente para operar sobre condições adversas e consegue generalizar sua resposta a partir de um conjunto representativo de padrões.

A rede neural pode ser configurada para reproduzir o funcionamento do sistema e determinar, através de comparação com o sistema real, se ocorre ou não alguma falha. Pode-se também utilizar a rede neural para classificação de falhas. Para isso verificam-se os padrões existentes nos tipos de falhas e treina-se a rede com estes valores. A classificação pode ser supervisionada ou não-supervisionada.

O uso da rede neural na detecção e classificação exige um conjunto representativo de dados do problema para o mapeamento. Com isto, a rede pode generalizar seu mapeamento para qualquer outra entrada diferente da apresentada no momento do treinamento.

Capítulo 3

Sensores Inteligentes na Rede Foundation Fieldbus

3.1 Introdução

Uma rede industrial é uma rede local para a interconexão de dispositivos no ambiente industrial. O objetivo da rede é controlar ou supervisionar processos realizando a comunicação entre supervisórios, CLP's, sensores, atuadores, computadores... As redes industriais surgiram para que houvesse uma descentralização das funções de controle em um processo industrial.

As redes industriais surgiram em meados da década de 80 seguindo uma tendência de descentralização das funções de controle em um processo industrial e da ascensão da tecnologia digital. Nas arquiteturas de sistemas industriais mais antigas, os dispositivos de um processo industrial eram conectados a um único elemento centralizador, responsável por toda a estratégia de controle do sistema. Com o avanço das técnicas de transmissão de dados em ambientes industriais através de redes digitais e a criação de padrões de comunicação entre instrumentos, o controle centralizado de processos industriais vem dando lugar ao controle distribuído [D. R. V. Pereira 2005].

Este capítulo apresenta o protocolo *Foundation Fieldbus*, as vantagens do padrão, como funciona a comunicação entre instrumentos, os níveis de rede e o modelo de comunicação de camadas proposto pelo protocolo. O capítulo ainda apresenta os sensores inteligentes e como são configurados os sensores no ambiente FF.

3.2 Rede *Foundation Fieldbus*

O Foundation Fieldbus(FF) é um sistema de comunicação totalmente digital, em série e bidirecional que conecta equipamentos de campo tais como sensores, atuadores e con-

troladores. O Fieldbus é uma rede local (LAN) para automação e instrumentação de controle de processos, com capacidade de distribuir o controle no campo [SMAR 2006].

O Foundation Fieldbus é um padrão aberto que possibilita dispositivos de diferentes fabricantes serem integrados em um único sistema (interoperabilidade). Isto é possível apenas quando todos os dispositivos seguem exatamente a especificação. Os dispositivos aprovados pela Fieldbus Foundation são uma garantia para o usuário e o fabricante que eles seguem a especificação, e possuem a logomarca da fundação.

Outras vantagens do protocolo são:

- Redução de custos iniciais: A instalação de uma rede fieldbus (que é multiponto) requer 1/5 menos cabos do que as ponto-a-ponto. Com relação ao padrão 4 - 20mA, que requer um par de fios para cada dispositivo, o fieldbus requer apenas um par-trançado de fios para toda a rede. O sistema requer menos trabalho para instalação e economiza dinheiro devido a redução de material necessário para instalação. Além do mais, o projeto do sistema é mais rápido devido a sua pouca complexidade.
- Simples manutenção: A simplicidade de configuração do sistema traz uma maior segurança para instalação do sistema e uma menor necessidade de manutenção. Os dispositivos informam seu estado *online* facilitando a depuração do sistema a procura de erros.
- Flexibilidade: Alguns algoritmos e procedimentos podem ser embarcados nos dispositivos de campo e não mais em um programa de controle. Um instrumento de campo pode ser calibrado, inicializado, operado e reparado numa velocidade considerável. Isto leva a uma redução do tempo total requerido para operar um sistema fieldbus.

3.2.1 Arquitetura da rede industrial

A especificação Foundation Fieldbus é baseada no modelo de comunicação em camadas e consiste de três elementos principais, como visto na figura 3.1 [SMAR 2006]. O nível físico FF equivale ao da camada física OSI. Sua principal particularidade é o fato de que a alimentação dos dispositivos pode usar o mesmo cabo onde trafegam os dados. A camada de comunicação é responsável pela comunicação entre os dispositivos e a camada de aplicação com o usuário fornece recursos gráficos para configurar os dispositivos da rede.

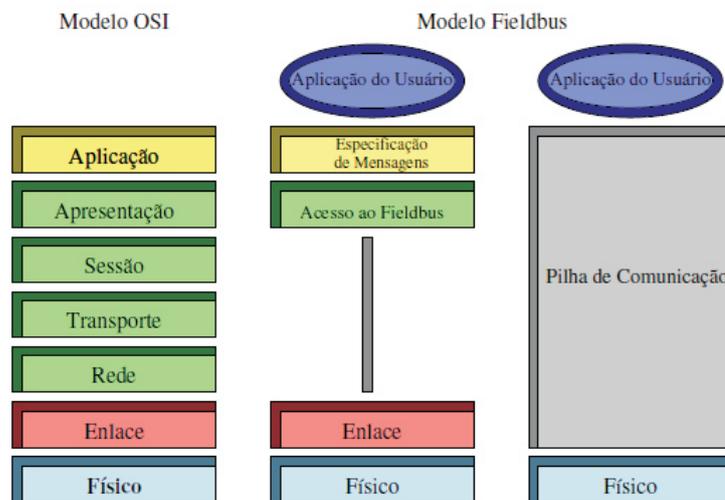


Figura 3.1: Comunicação em camadas do sistema OSI e do Fieldbus

A camada de aplicação do usuário fornece blocos de *software* que são os blocos de recursos, blocos transdutores e blocos funcionais.. As funções de cada tipo de bloco estão explicados logo abaixo [Costa 2006]:

- Blocos de recurso: São usados para a descrição do dispositivo, informando o seu nome, fabricante, versões de *hardware* e *firmware*, entre outras informações.
- Blocos transdutores: Transformam os dados digitais em analógicos e vice-versa, podendo ser usado para calibrar, deslocar medidas, posicionar dados, linearizar características e converter unidades físicas.
- Blocos funcionais: Os blocos funcionais processam funções matemáticas pré-definidas como somatório, média aritmética, sintetiza funções, entre outras.

Duas implementações são introduzidas pelo protocolo para a comunicação dos instrumentos e são utilizadas de acordo com a necessidade de cada ambiente do processo de automação. A rede H1 e HSE. A Rede H1 que opera com velocidade de 31.25 kbps e geralmente conecta dispositivos do campo. A rede HSE(*High Speed Ethernet*) opera a uma velocidade de 100 Mbps, possibilita a interconexão de barramentos H1 e também é utilizado para ligação de dispositivos de alta velocidade.

3.2.2 Blocos funcionais

Os blocos funcionais implementam funções usadas em aplicações de controle. Eles podem instanciar controladores, condicionar funções, realizar operações matemáticas ou

até mesmo operações lógicas. Estratégias avançadas de controle também podem ser implementadas utilizando um conjunto destes blocos. Esta é a proposta do trabalho, implementar um mapa auto-organizável a partir de blocos funcionais padrão.

Foi utilizado neste trabalho a construção do mapa a partir de blocos funcionais padrão. Os principais blocos utilizados foram o bloco aritmético, o bloco caracterizador de sinais e o bloco seletor de entrada. A figura 3.2 apresenta o esquema de um bloco aritmético. Este bloco possui três entradas e pode ser configurado para realização cálculos matemáticos, como a soma tradicional e a média aritmética das entradas. A operação matemática realizada é definida no parâmetro ARITH_TYPE e as três entradas e a saída da rede estão esquematizadas respectivamente por IN_1, IN_2, IN_3 e OUT.

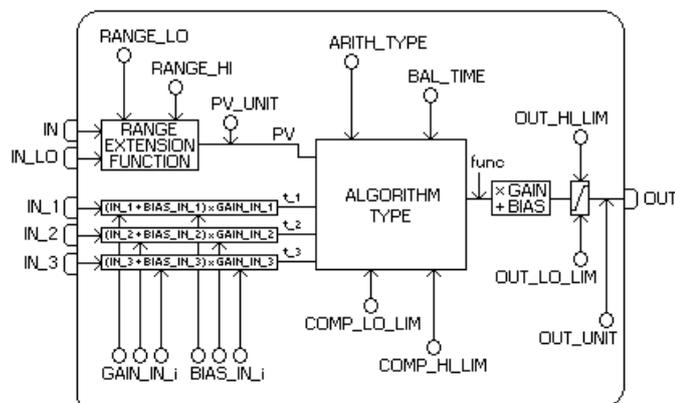


Figura 3.2: Bloco funcional Aritmético

O bloco caracterizador de sinais (SCHAR) permite o condicionamento de uma função. A configuração é realizada definindo os vinte melhores pontos do gráfico que melhor represente a função. Com isso, o bloco realiza a interpolação destes pontos para representar a função. Com a função definida pode-se utilizar o bloco para fazer o mapeamento de entrada e saída utilizando qualquer valor de entrada. A figura 3.3 apresenta o caracterizador de sinais.

Para facilitar o processo de configuração dos blocos, o caracterizador de sinais permite dois canais de mapeamento no mesmo bloco SCHAR, desta forma as duas entradas IN_1 e IN_2 são mapeadas com a mesma função em OUT_1 e OUT_2, respectivamente.

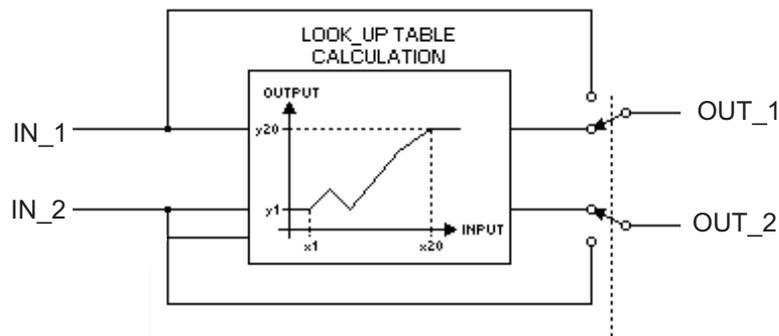


Figura 3.3: Bloco caracterizador de sinais

Outro bloco importante é o bloco seletor de entrada (ISEL). O bloco ISEL é definido para realizar uma comparação entre as suas 4 entradas e transferir para a entrada selecionada o índice de tal entrada. O ISEL é configurado no parâmetro SELECT_TYPE para escolher a maior ou menor saída. Também pode ser utilizado para determinar a média de todas as entradas ou selecionar a primeira entrada apta para a leitura.

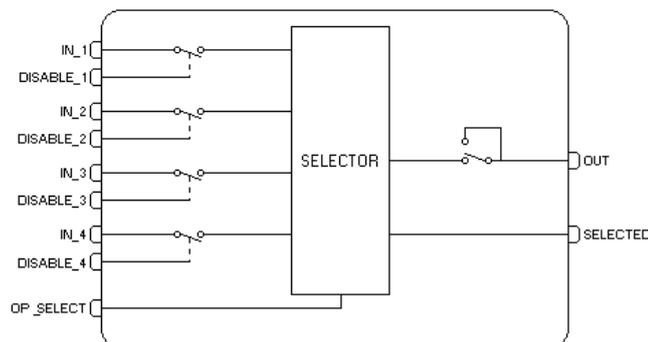


Figura 3.4: Bloco seletor de entrada

3.3 Sensores inteligentes

Sensores inteligentes são sensores com poder computacional para realização de tarefas e para automatizar o processo. A vantagem é que com esse tipo de sensor possibilita que o processamento seja feita localmente, dentro dos dispositivos de campo e de forma distribuída pelo processo.

O sensor inteligente pode determinar qual deverá ser o sinal de controle para um atuador, determinar a ocorrência de uma falha de leitura, classificar o estado de operação do processo para que, desta forma, o operador tenha informações mais precisas de como proceder na solução de um problema. Outro uso bastante interessante neste tipo de sensores

é a configuração de *Software Sensor* para que, através de medições indiretas, se consiga determinar algumas variáveis do processo. Vários trabalhos foram desenvolvidos para a construção de sensores inteligentes em controle e automação. Como exemplo temos a configuração de um neurônio artificial utilizando somente blocos funcionais padrão da rede *Foundation Fieldbus*.

O neurônio artificial é desenvolvido a partir do bloco funcional aritmético e do bloco caracterizador de sinais. Os pesos aplicados a cada entrada, como descrito na figura 3.2 são utilizados para representar os pesos sinápticos da rede e o bloco caracterizador de sinais, devidamente configurado, é utilizado para caracterização da função de ativação do neurônio. A figura 3.5 apresenta o modelo de um neurônio com três entradas.



Figura 3.5: Neurônio artificial implementado através de blocos funcionais

Como o número de entradas no bloco ARITH é limitado a três entradas, quando precisamos de um neurônio com mais entradas devemos utilizar mais blocos aritméticos. Por exemplo, veja a figura 3.6. Os Blocos Aritméticos 1 e 2 recebem seis entradas. Cada bloco é configurado com os seus devidos pesos, o resultado do produto interno xw^f é calculado na saída do terceiro bloco aritmético que une as saídas dos dois primeiros. O resultado é passado para o bloco SCHAR, que tem condicionado uma função de ativação.

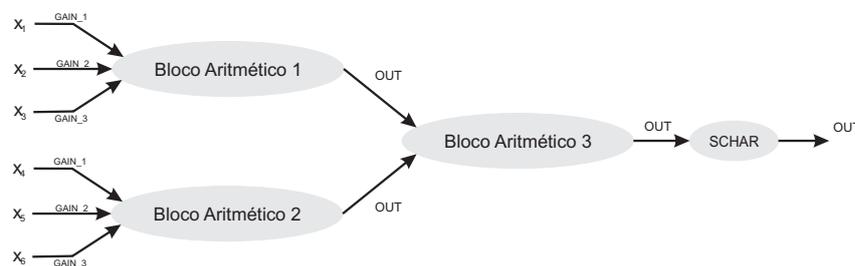


Figura 3.6: Neurônio artificial com 6 entradas implementado através de blocos funcionais

O bloco funcional SCHAR pode ainda servir outra entrada para um segundo neurônio através do seu outro canal de mapeamento entrada-saída para a construção da rede neural.

Capítulo 4

Metodologia

4.1 Introdução

Este capítulo aborda a metodologia para o embarque de um mapa SOM na rede industrial Foundation Fieldbus utilizando os blocos padrões descritos em 3.2.2. Também será abordado os padrões de entrada da rede e o procedimento utilizado para a determinação do neurônio vencedor.

4.2 Algoritmo para diagnóstico de falhas

A classificação de falhas foi desenvolvida utilizando os dados preditos de um e dois passos de uma rede NARX previamente treinada. Através do erro de predição é possível determinar as falhas, caso o erro ultrapasse um limite pré-estabelecido.

Existem dois tipos básicos de falhas que um sensor pode apresentar:

- Falha abrupta: Ocorre quando há um falha repentina no sensor e é modelado como um degrau.
- Falha Incipiente: É uma falha que aumenta lentamente com o tempo e é modelada por derivas de medição.

Várias falhas podem ser derivadas desses dois tipos básicos. Neste trabalho foi modelado duas falhas abruptas e duas falhas incipientes, descritas nos itens abaixo. Portanto, a série temporal pode estar sob os seguintes estados de operação.

- Ausência de falha: Funcionamento normal do sensor.
- Valor zero: O sensor fornece somente a saída zero.
- Valor de fundo de escala: O sensor passa a fornecer abruptamente o valor de fundo de escala em sua medição.

- Deriva do fator de escala: O fator de escala do sensor se altera ao longo do tempo.
- Deriva de *offset*: Um sinal de *offset* crescente ou decrescente é adicionado à saída do sensor.

Observa-se que a modelagem destas falhas pode ser aplicada a qualquer tipo de sensor, pois a intenção não é detalhar a relação entre as falhas de sinal e as falhas físicas, intrínsecas de cada dispositivo. Este é um estudo minucioso que requer uma análise aprofundada das características de cada tipo de sensor para identificar todas as possíveis falhas que podem ocorrer [de Medeiros 2009]. 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.

A detecção da presença de falhas é realizada analisando a diferença entre o valor predito e o valor real da saída do sensor, de acordo com as entradas definidas em 4.1. O padrão é formado pela variação da entrada real e a variação da entrada estimada com o último valor real.

$$I = \begin{bmatrix} y(n) - y(n-1) \\ \hat{y}(n) - y(n-1) \end{bmatrix} = \begin{bmatrix} \Delta y(n) \\ \Delta \hat{y}(n) \end{bmatrix} \quad (4.1)$$

Desta forma, espera-se que a variação real apresente um resultado anômalo antes da variação estimada, caracterizando assim a existência de uma falha. O classificador está representado na figura 4.1. A falha ocorre quando $\Delta y(n)$ é alterado significativamente e o valor estimado $\Delta \hat{y}(n)$ permanece inalterado durante o tempo equivalente aos passos de predição.

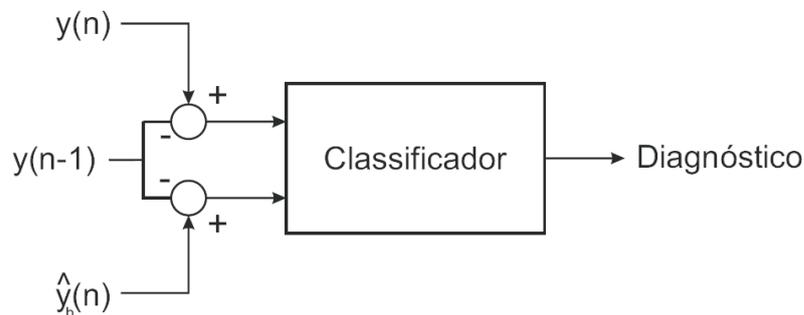


Figura 4.1: Esquema de diagnóstico de falhas

4.3 Procedimentos

Os dados utilizados para testes foram obtidos a partir de uma estação de medição de gás natural no período de um mês, com intervalos de amostragem de uma hora. Foram coletados em auditorias realizadas pelo [CTGÁS 2007] em pontos de medição fiscal de gás natural. O conjunto é formado por 684 valores de temperatura (figura 4.2).

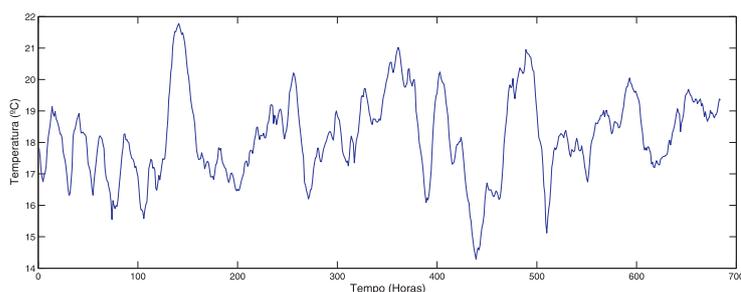


Figura 4.2: Esquema de diagnóstico de falhas

Estes dados foram utilizados para construir uma rede neural NARX para predição de um e dois passos. A predição foi utilizada como parâmetro para determinação da falha. Com a falha descoberta, utilizamos a variação real $\Delta y(n)$ e uma variação estimada $\Delta \hat{y}(n)$ conforme descreve a figura 4.1 para diagnosticar tal falha. Supondo que ocorreu alguma falha quando o sensor apresentar um resultado muito diferente do valor estimado pela predição.

As falhas consideradas são as definidas em 4.2. Elas foram simuladas em instantes de tempos diferentes em 15 sinais e modeladas para terem os 4 tipos de falhas. As seguintes equações modelam estas falhas:

- Valor zero: $y(t) = 0$;
- Valor de fundo de escala: $y(t) = 60$;
- Deriva do fator de escala: $y(t) = y(t)e^{(-ak)}$, tal que $a = 0.06$ e a variável k assume 1 em que se inicia o estado da falha e é incrementada a cada instante de tempo subsequente.
- Deriva de *offset*: $y(t) = y(t) - ak$, tal que $a = 0.6$ no instante inicial da falha e é incrementada a cada instante que a falha permaneça.

As quatro falhas estão representadas na figura 4.3 e a figura 4.4 apresenta o resultado da predição de dois passos da série sem falhas nos sensores. Observe que existe um erro perceptível na predição de dois passos. Este erro facilita o processo de classificação. Foi

verificado que com uma NARX de passos múltiplos as falhas são melhores diagnosticadas do que com passos simples.

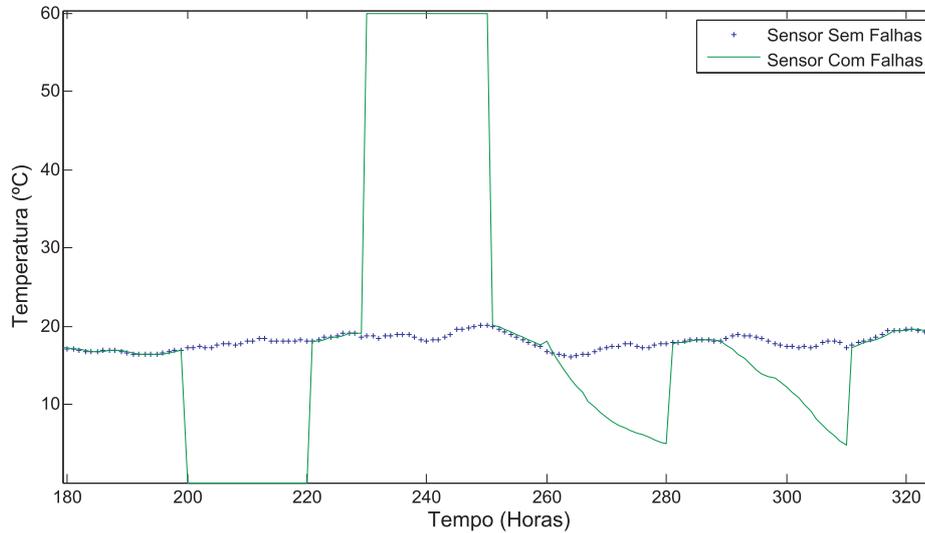


Figura 4.3: Quatro falhas simuladas

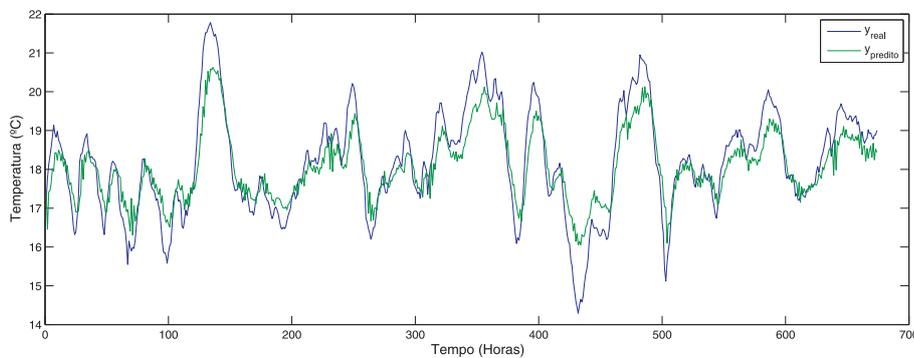


Figura 4.4: Predição de 2 passos

4.4 Mapa SOM

A implementação do mapa SOM foi idealizado para um modelo com 9 neurônios numa grade bidimensional. Os neurônios têm nas entradas os valores da variação real $\Delta y(n)$ e variação predita $\Delta \hat{y}(n)$, como indicado na equação 4.1. A rede esquematizada na figura 4.5 apresenta o modelo dos neurônios configurados nos blocos funcionais. Os neurônios foram colocados verticalmente somente por facilidade de implementação, mas o treinamento foi realizado pensando em um grid hexagonal. Os três primeiros são os

Topologia	3x3
Função de distância	Distância Euclidiana
Taxa de aprendizagem	$\eta(n=0) = 0.9$
Épocas	1000

Tabela 4.1: Parâmetros para o mapa SOM

neurônios da primeira fila, os três do meio da fila central e o restante são os neurônios da última fila.

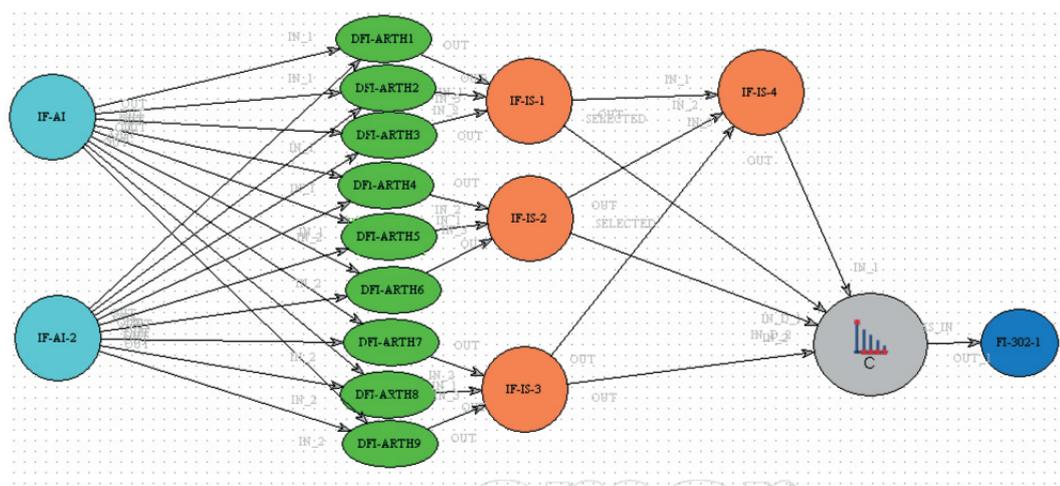


Figura 4.5: Neurônios da rede SOM

Os dados foram tratados de forma a possuírem diferentes tipos de erros em diferentes instantes de tempo da série e o treinamento foi realizado em Matlab© com os parâmetros descritos na tabela 4.1.

No mapa SOM da figura, os blocos em azul claro 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 entrada. Como utilizamos duas entradas, a terceira entrada ficou desabilitada para o funcionamento.

Cada neurônio faz a ponderação das entradas e apresenta uma saída disponível para a rede. De forma que a saída geral da rede será definida pelo índice da melhor saída, correspondendo ao neurônio que possuir a maior resposta ao estímulo de entrada. Os blocos ISEL (em laranja na figura 4.5 não são conclusivos em determinar, como uma única saída, o neurônio vencedor. Por isso, o bloco em cinza realiza o mapeamento das 4 respostas individuais dos blocos seletores e retorna um índice entre 1 e 9 correspondente ao neurônio vencedor.

O que acontece é que 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. Seria ideal que tivéssemos 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. Para tanto foi determinado uma rede neural 4:1 que mapeia os 4 padrões a uma saída desejada em apenas uma única resposta, o índice do neurônio vencedor. A tabela 4.2 apresenta três exemplos de padrões de mapeamento apresentados à rede. Na tabela, o grupo vencedor é aquele que possui o neurônio com maior saída geral. Esta rede é o bloco em cinza da figura.

Vencedor fila 1	Vencedor fila 2	Vencedor fila 3	Grupo vencedor	Resposta desejada
1	2	2	2	5
3	2	2	2	3
3	2	1	3	7

Tabela 4.2: Exemplos de padrões mapeados para determinação do neurônio vencedor

Como cada fila possui três neurônios, e existem apenas três grupos possíveis de vencedores, temos então que a rede neural precisa mapear $81(3^4)$ padrões. A rede neural para mapear os neurônios vencedores de cada fila em apenas um neurônio vencedor foi uma MLP definida. Os neurônios desta rede também foram construídos através de blocos funcionais padrão como descrito na metodologia para construção de neurônios no ambiente *Foundation Fieldbus*.

Capítulo 5

Resultados

Os resultados serão apresentados neste capítulo de acordo com a metodologia adotada no capítulo 4. Foi observado que a predição com passos múltiplos é mais eficaz para a detecção de uma falha. Isto ocorre porque existe um erro mais significativo entre predição e o real medido. Para constatar que existe uma falha, observarmos a diferença entre o valor predito e o valor estimado. Quando esta diferença ultrapassar um limite de tolerância, dizemos que está ocorrendo uma falha.

O trabalho desenvolvido utiliza a rede NARX de predição de passos múltiplos ($h=2$) para a classificação de falhas. A predição é utilizada para compor uma das entradas mapa SOM que é montado a partir de uma análise de erro da dinâmica real e estimada do sistema.

Uma análise do erro está esquematizado na figura 5.1, no gráfico estão o erro estimado ($\Delta\hat{y}(t)$) e do erro real ($\Delta y(t)$). Observe quando ocorre uma falha, o sensor modifica abruptamente seu valor e o preditor se mantém estável por um tempo, logo depois diverge na tentativa de acompanhar o valor real (figura 5.1). Este *delay* provocado pelo preditor facilita a detecção e distingue melhor os padrões existentes na série.

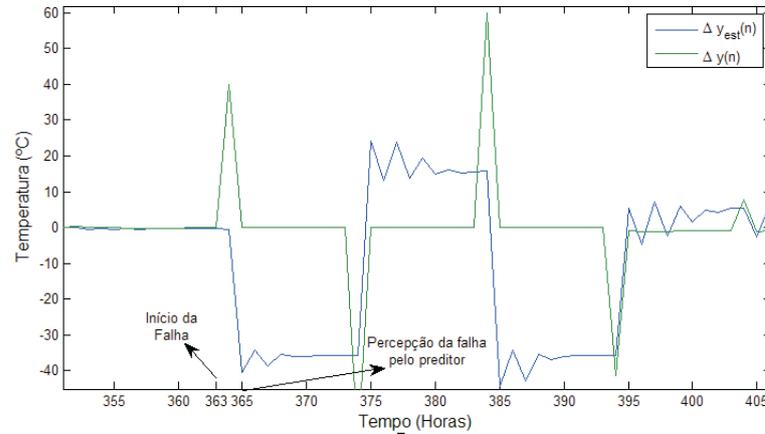


Figura 5.1: Percepção da falha vista pelo sensor e pelo preditor

Os valores dos erros foram transferidos à rede utilizando o padrão OPC (OLE for process control) e as saídas recebidas pelo mesmo padrão com a resposta do neurônio ativado.

Para facilitar a análise das falhas, um novo gráfico foi montado onde os locais das falhas foram marcados. A altura corresponde ao estado de funcionamento da série temporal. Veja na figura 5.2 um exemplo deste gráfico. Foi convencionado que o funcionamento normal ocorre quando o gráfico está sobre o eixo x.

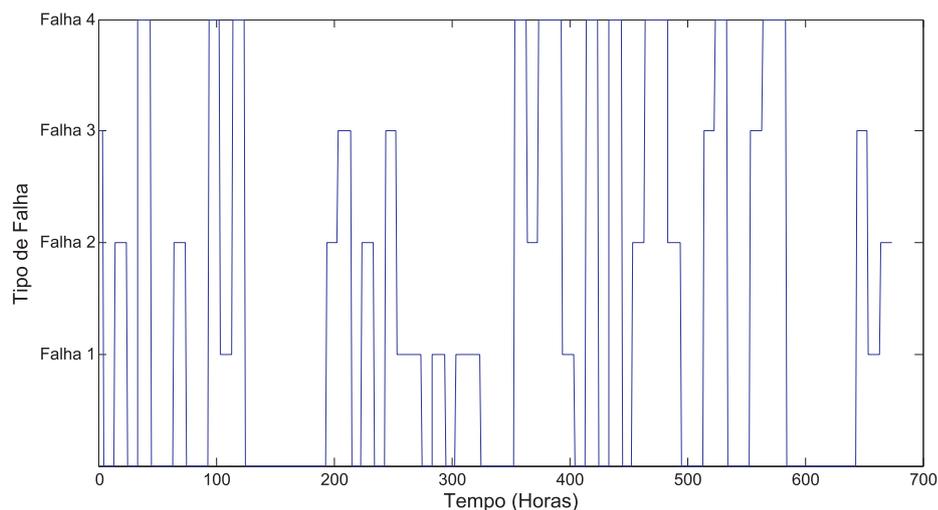


Figura 5.2: Estado de funcionamento do sensor

Este gráfico exhibe os quatro principais padrões que surgem para diagnóstico de falhas. O teste pode ser realizado então, verificando o estado de atuação de cada neurônio na

presença desses padrões.

A figura 5.3 mostra o estado de ativação do neurônio 2. Observe que em todo momento que surgiu a falha, o detector identificou automaticamente, e permaneceu até o momento de fim da falha.

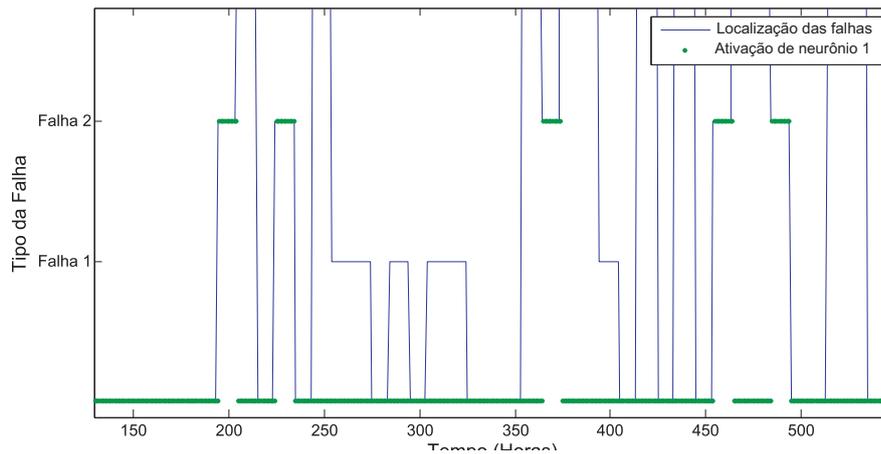


Figura 5.3: Estado de ativação do neurônio 1 na presença da falha 2

Também foram detectados a formação de cluster's de neurônios para a classificação de um mesmo padrão. Observe na figura 5.4 a excitação do neurônio 9 na classificação da falha 1. É interessante notar que no instante inicial e final da falha não ocorre a ativação do neurônio 9, porém durante todo o restante o neurônio foi ativado.

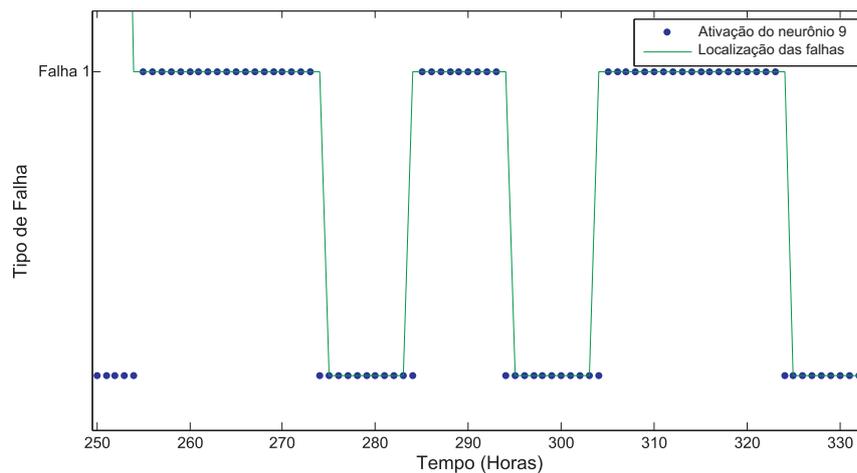


Figura 5.4: Estado de ativação do neurônio 9 na presença da falha 1

Verificando a ativação do neurônio 3 encontramos que em todo momento que se inicia a falha 1 ele é excitado. Isto acontece somente no momento em que inicia-se a falha.

Podemos então dizer que existe a falha 1 quando o neurônio 3 ou o 9 estão excitados. A figura 5.5 ilustra a ativação do neurônio 3.

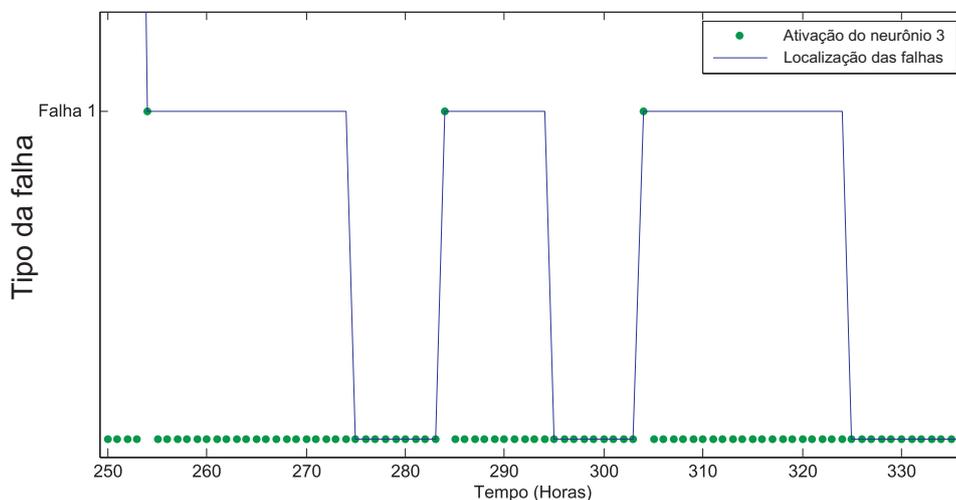


Figura 5.5: Estado de ativação do neurônio 3 na presença da falha 1

As falhas 1 e 2 pertencem a um padrão mais fácil de se detectar, enquanto que os padrões 3 e 4 são muito parecidos e não houve uma distinção completa de qual neurônio ativa na presença falha 3 e qual ativa na presença da falha 4. A tabela 5.1 apresenta a classificação de cada falha em função do neurônio ativado.

Falha	Neurônio Ativado
1	9 e 3
2	1 e 8
3	4 e 7
4	4 e 7

Tabela 5.1: Classificação da falha em função do neurônio ativado

De acordo com a classificação da falha em função do neurônio ativado, foi montado um mapa de confusão. Para isso foi apresentado à rede vários pontos de falhas e verificado em qual classe ela foi atribuída. O mapa está relacionado em 5.2.

Os melhores resultados foram encontrados nas falhas abruptas, com quase 98.8% de classificação correta para F_1 e 100% para falha 2. Apesar da falha 1 não conseguir a totalidade de classificação, observamos que o início da falha sempre é diagnosticado corretamente em todos os sinais de temperatura analisados. Permitindo, desta forma, que o operador do processo intervenha rapidamente para a correção do problema do sensor. Em pouquíssimas vezes (1.2%) a falha é diagnosticada incorretamente e ocorre no fim,

Tipo/Classe	F_1	F_2	F_3	F_4
F_1	98.80%	1.11%	0.00%	0.09%
F_2	0%	100%	0.00%	0.00%
F_3	2.19%	1.86%	94.90%	94.90%
F_4	2.93%	1.01%	93.13%	93.13%

Tabela 5.2: Mapa de confusão

quando a dinâmica da predição e do sistema real estão se igualando novamente. As falhas de deriva obtiveram resultados inferiores devido a natureza do problema, de forma que não é possível distinguir com exatidão cada uma.

Na tabela observamos que a classificação de F_3 em F_4 e F_4 em F_3 obtiveram o mesmo resultado de sua correta classificação. Este resultado condiz com a realidade, já que as falhas 3 e 4 são diagnosticadas quando os mesmos neurônios são ativados. Com isso podemos dizer que o mapa SOM conseguiu classificar com bom desempenho as falhas de derivação e falhas abruptas.

Capítulo 6

Considerações Finais

Durante as transferências de custódias do gás, as empresas devem verificar se a quantidade real de massa de gás transferida corresponde ao valor pago. Por isso, durante a transferência o produto deve ser monitorado constantemente e é indispensável que os sensores estejam funcionando corretamente.

Neste trabalho implementa-se uma estratégia de monitorar o funcionamento do sensor realizando as tarefas de detecção e principalmente a análise de qual falha está acontecendo. Foi abordado como proceder para classificação do defeito do sensor baseado em quatro tipos de falhas comuns.

O SOM é uma proposta interessante na classificação porque é utilizado um aprendizado não-supervisionado para o seu treinamento. Desta forma, pode-se generalizar o problema para diferentes condições de operação do sensor sem o conhecimento prévio de como se comporta a dinâmica da falha no sensor.

Os resultados mostraram que uma falha é mais fácil de ser diagnosticar com passos múltiplos de predição. Principalmente quando temos falhas diferentes com comportamentos parecidos, como é o caso das falhas de derivação.

Ainda é possível generalizar a configuração do mapa SOM na rede FF para um número maior de neurônios e que desta forma classifique uma quantidade maior de falhas, ou mesmo diferencie as falhas incipientes. O mapa verifica qual falha está ocorrendo no sensor através utilizando a dinâmica do sensor. Por isso seria útil também incluir outra entrada ao mapa que seria a diferença entre o valor predito e o valor real para realizar não somente o diagnóstico da falha como poder detectá-la.

Como sugestão de trabalhos futuros estão o estudo mais detalhado dos tipos de falhas que podem ocorrer em um sensor para poder incorporar a rede auto-supervisionada e também a implementação da rede ART (Adaptive Resonance Theory) para o diagnóstico de falhas dentro do ambiente *Foundation Fieldbus*.

Referências Bibliográficas

Costa, I. M. (2006), Projeto e implementação em ambiente foundation fieldbus de filtragem estocástica baseada em análise de comportamento independentes, Dissertação de mestrado, Universidade Federal do Rio Grande do Norte.

CTGÁS (2007), ‘<http://www.ctgas.com.br/>’, acessado em 21/11/2007’.

D. R. V. Pereira, E. G. Júnior, R. Wendell A. D. D. Neto J. D. Melo (2005), ‘Auto-compensação de sensores *Foundation Fieldbus* utilizando redes neurais recorrentes através de blocos funcionais’, *VII Congresso Brasileiro de Redes Neurais* .

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.

Fernandes, R. G. (2007), Detecção e isolamento de falhas em sistemas dinâmicos baseados em redes neurais, Dissertação de mestrado, Universidade Federal do Rio Grande do Norte.

Haykin, Simon (2001), *Redes Neurais - Princípios e Prática*, Bookman.

SMAR (2006), *Tutorial Fieldbus Foundation*, Smar International Corporation, Sertãozinho, Brasil.