Universidade de São Paulo
Escola de Engenharia de São Carlos

Rafaela Castelhana de Souza

**Diagnóstico da Camada Física de Redes Profibus DP
Baseado em Redes Neurais Artificiais**

São Carlos
2012

Rafaela Castelhana de Souza

**Diagnóstico da Camada Física de Redes Profibus DP
Baseado em Redes Neurais Artificiais**

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciências, Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos – Universidade de São Paulo.

Área de concentração: Sistemas Dinâmicos

Orientador:
Prof. Dr. Dennis Brandão

São Carlos
2012

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento da Informação do Serviço de Biblioteca – EESC/USP

Souza, Rafaela Castelhana de.

S731d Diagnóstico da camada física de redes Profibus DP baseado em redes neurais artificiais. / Rafaela Castelhana de Souza ; orientador Dennis Brandão. São Carlos, 2012.

Dissertação – Mestrado (Programa de Pós-Graduação em Ciências em Engenharia Elétrica e Área de Concentração em Sistemas Dinâmicos) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2012.

1. Redes Profibus. 2. Automação industrial. 3. Diagnóstico. 4. Redes neurais. I. Título.

FOLHA DE JULGAMENTO

Candidata: Engenheira **RAFAELA CASTELHANO DE SOUZA**.

Título da dissertação: "Diagnóstico da camada física de redes profibus DP baseado em redes neurais artificiais".

Data da defesa: 12/04/2012

Comissão Julgadora:

Resultado:

Prof. Dr. **Dennis Brandão (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

aprovada

Prof. Associado **Ivan Nunes da Silva**
(Escola de Engenharia de São Carlos/EESC)

APROVADA

Prof. Dr. **Carlos Eduardo Pereira**
(Universidade Federal do Rio Grande do Sul/UFRGS)

APROVADA

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Titular **Denis Vinicius Coury**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo Cesar Lima Segantine**

DEDICATÓRIA

Dedico este trabalho aos meus pais, Adelma e Donizetti, por todo amor, carinho e força que dispensam a mim, sempre. E às minhas irmãs, Mirella e Isabella, melhores amigas que tenho na vida.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me dado força e coragem para continuar cada vez que eu pensava em desistir;

Aos meus amados pais, Adelma e Donizetti, por tudo que fizeram e fazem por mim. Por todos os conselhos, conversas, momentos, que ficarão sempre guardados no meu coração. Por estarem sempre do meu lado, em todos os momentos;

Às minhas irmãs Mirella e Izabella, meus avós e toda minha família, por todo carinho dispensado a mim, sempre;

Ao meu noivo Luciano pelo amor, compreensão e paciência nos momentos de cansaço e ausência;

Ao meu orientador Professor Dennis Brandão, pela atenção, conselhos e dedicação no decorrer deste trabalho;

Aos colegas de grupo Eduardo Mossin e Renato Veiga por toda ajuda dispensada;

Aos colegas do Laboratório de Automação pela ajuda na coleta dos dados, em especial ao Guilherme Sestito;

À SMAR por ter me liberado para o mestrado e aos colegas de trabalho pelas ajudas prestadas;

À USP São Carlos, por colocar à disposição sua estrutura;

Ao meu diretor César Cassiolato por ter me ensinado tanto nesse tempo e ter esclarecido todas as minhas dúvidas;

Aos amigos Fabiana e Sergio Vianna pela ajuda técnica;

RESUMO

SOUZA, R. C. (2012). **Diagnóstico da Camada Física de Redes Profibus DP baseado em Redes Neurais Artificiais**. 127p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

A rede PROFIBUS DP é o barramento de campo mais utilizado na indústria mundial atualmente. Com o uso cada vez maior desta rede de “chão de fábrica” nas plantas industriais, o diagnóstico rápido de falhas tornou-se extremamente necessário e importante, o que permite minimizar os tempos de parada da instalação e consequentes prejuízos no processo produtivo. Este trabalho apresenta o estudo de técnicas baseadas em Redes Neurais Artificiais (RNA) que serão utilizadas em um trabalho futuro para se fazer um diagnóstico rápido de uma rede PROFIBUS em caso de falha, permitindo através dos conceitos básicos apresentados, uma análise criteriosa do seu desempenho. Inicialmente são apresentados conceitos básicos sobre as redes PROFIBUS DP, tais como arquitetura e versões do protocolo, a descrição da Camada Física, dentre outros assuntos relevantes. Nas etapas seguintes, serão apresentados outros tópicos importantes para entendimento do projeto como, conceitos sobre RNA e métodos de pré-processamento do sinal colhido no osciloscópio.

Palavras-Chave: Automação Industrial, Redes Profibus, Diagnóstico, Redes Neurais Artificiais, Processamento de Sinais.

ABSTRACT

SOUZA, R. C. (2012). **Physical Diagnostic for Profibus DP Networks Based on Artificial Neural Networks**. 127p. Thesis (Master) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

The PROFIBUS (Process Field Bus) DP is the most popular fieldbus communication used in the worldwide industry. With the increasing use of this network fieldbus in industrial plants, the rapid faults' diagnosis has become extremely necessary and important, which minimizes the lodgment's time and consequent losses in the production process. This work is based into a Artificial Neural Networks' (ANN) tool that will be used to make a rapidly diagnosis of a PROFIBUS network in case of failure, allowing through basic concepts, a careful review of their performance. First the basics of PROFIBUS DP networks are presented, such as architecture and protocol versions, a description of the Physical Layer, among other relevant issues. In the following steps, others important topics to understand the project will be shown, such as, concepts of ANN and pre-processing methods from collected signal.

Keywords: Industrial Automation, Profibus Networks, Diagnostic, Artificial Neural Network, Signal Processing.

LISTA DE FIGURAS

Figura 2.1 - Modelo de Referência ISO/OSI aplicado à Rede Profibus.....	8
Figura 2.2 - Codificação NRZ.....	9
Figura 2.3 - Exemplo de um Sinal Diferencial com Ruído.....	10
Figura 2.4 - Caracter Profibus DP.....	11
Figura 2.5 - Pinagem do Conector Sub-D com 9 Pinos.....	15
Figura 2.6 - Conector M12 com 5 Pinos.....	16
Figura 2.7 - Exemplo de Cabo com Terminação.....	17
Figura 2.8 - Exemplo de uma Rede com Terminadores de Barramento e Repetidores.....	17
Figura 2.9 - Falta de Terra no Equipamento.....	20
Figura 2.10 - Blindagem sem Contato com o Conector.....	20
Figura 2.11 - Sinal Diferencial Mostrado em um Osciloscópio.....	24
Figura 3.1 - Comparativo entre o Modelo de Neurônio proposto por McCulloch e Pitts e o Modelo de Neurônio Biológico.....	32
Figura 3.2 - Função de Ativação do Tipo Linear.....	33
Figura 3.3 - Função de Ativação do Tipo Rampa.....	34
Figura 3.4 - Função de Ativação do Tipo Degrau Bipolar.....	34
Figura 3.5 - Função de Ativação do Tipo Sigmoidal.....	35
Figura 3.6 - Exemplo de uma Rede PMC com uma Camada Intermediária.....	36
Figura 4.1 - Características Aceitáveis de um Sinal Profibus.....	51
Figura 4.2 - Sinal Profibus DP sem Problema de Comunicação.....	51
Figura 4.3 - Sinal Profibus DP com Problema de Cabo Longo.....	52
Figura 4.4 - Sinal Profibus DP com Problema de Falta de Terminador.....	53
Figura 4.5 - Exemplo de Circuito com Impedâncias em Paralelo.....	54
Figura 4.6 - Sinal Profibus DP com Problema de Excesso de Terminador.....	55
Figura 4.7 - Esquema da relação entre a quantidade de pontos/bit e a quantidade de bits representando uma situação da rede.....	55
Figura 4.8 - Esquema da Rede Profibus DP Utilizada na Coleta dos Dados.....	59
Figura 4.9 - Esquema Geral do Projeto.....	60
Figura 4.10 - Esquema do Cálculo do Número de Pontos/Bit.....	63
Figura 4.11 - Exemplo de uma Rede Funcionando Normalmente.....	64
Figura 4.12 - Exemplo de uma Rede com Problema devido a Curto-Circuito.....	65

Figura 4.13 - Exemplo de uma Rede com Problema devido a Cabo Rompido.....	66
Figura 4.14 - Exemplo de uma Rede com Problema devido a Cabo Longo.....	66
Figura 4.15 - Exemplo de uma Rede com Problema devido a Inversão entre as Linhas de Dados A e B.....	67
Figura 4.16 - Exemplo de um conjunto de treinamento contendo bits fora do padrão da classe apresentada.....	70
Figura 4.17 - Esquema de um conjunto de treinamento referente à classe apresentada.....	70
Figura 4.18 - Esquema de classificação dos dados utilizando-se uma RNA para cada situação da rede.....	73

LISTA DE TABELAS

Tabela 2.1 - Comprimento Máximo de Cabo por Segmento.....	13
Tabela 2.2 - Distâncias Mínimas de Separação entre Cabeamentos.....	14
Tabela 2.3 - Pinagem do Conector Sub-D com 9 Pinos.....	15
Tabela 2.4 - Características Funcionais dos Equipamentos de Mão.....	23
Tabela 2.5 - Características Principais das Ferramentas de Diagnóstico de Redes Profibus....	26
Tabela 4.1 - Dados de Treinamento da RNA.....	56
Tabela 4.2 - Porcentagem de Acerto.....	57
Tabela 4.3 - Resultados do Ensaio com Dados Reais.....	68
Tabela 4.4 - Porcentagem de Acerto para RNA com 22 pontos/bit.....	74
Tabela 4.5 - Porcentagem de Acerto para RNA com 67 pontos/bit.....	75
Tabela 4.6 – Dados de treinamento das RNAs com 22 entradas.....	75
Tabela 4.7 – Dados de treinamento das RNAs com 67 entradas.....	76

LISTA DE SIGLAS

ANFIS	Sistema de Inferência Neuro-Fuzzy Adaptativo (<i>Adaptative Neuro-Fuzzy Inference Systems</i>)
CCP	Centro de Competência Profibus
CLP	Controlador Lógico Programável
CSTR	<i>Continuously well-Stirred Tank Reactor</i>
DP	Periferia Descentralizada (<i>Decentralized Periphery</i>)
DWT	Transformada de Wavelet Discreta (<i>Discrete Wavelet Transform</i>)
EEG	Eletronecefalograma
FDT	Transformada Discreta de Fourier (<i>Fourier Discrete Transform</i>)
FFT	Transformada Rápida de Fourier (<i>Fast Fourier Transform</i>)
FMS	Especificação de Mensagem Fieldbus (<i>Fieldbus Message Specification</i>)
FT	Transformada de Fourier (<i>Fourier Transform</i>)
GNSS	<i>Genetic-based neural networks</i>
GSD	<i>General Slave Data</i>
HART	<i>Highway Addressable Remote Transducer</i>
IP	Grau de Proteção (<i>Ingress Protecion</i>)
LED	Diodo Emissor de Luz (<i>Light Emitting Diode</i>)
LVQ	Quantização Vetorial por Amostragem (<i>Learning Vector Quantization</i>)
MBP	<i>Manchester Bus Powered</i>
MFSK	Modulação por Chaveamento de Frequência Múltipla (<i>Multi Frequency Shift Keying</i>)
MPSK	Modulação por Deslocamento de Fase (<i>M-ary Phase-Shift Keying</i>)
MSE	Erro Quadrático Médio (<i>Mean Square Error</i>)
PMC	Perceptron Múltiplas Camadas (<i>Multilayer Perceptron</i>)
OLM	Módulo de Link Óptico (<i>Optical Link Module</i>)
PA	Automação de Processo (<i>Process Automation</i>)
PCA	Análise de Componentes Principais (<i>Principal Components Analysis</i>)
PC	Computador Pessoal (<i>Personal Computer</i>)
Profibus	<i>Process Field Bus</i>
QAM	Modulação em Amplitude e Quadratura (<i>Quadrature Amplitude Modulation</i>)
RNA	Redes Neurais Artificiais

SUMÁRIO

LISTA DE TABELAS	17
1 INTRODUÇÃO	1
1.1 OBJETIVOS	3
1.2 ORGANIZAÇÃO DO TRABALHO	3
2 PROTOCOLO PROFIBUS	5
2.1 ARQUITETURA DAS REDES PROFIBUS	7
2.2 CAMADA FÍSICA	8
a) RS-485	12
2.3 MÉTODOS DE DIAGNÓSTICO EXISTENTES	18
2.3.1 INSPEÇÃO VISUAL	19
2.3.2 TESTES UTILIZANDO MULTÍMETRO	20
2.3.3 TESTE UTILIZANDO DISPOSITIVOS DE MÃO	22
2.3.4 TESTE UTILIZANDO O OSCILOSCÓPIO	24
2.3.5 TESTES UTILIZANDO REPETIDORES COM DIAGNÓSTICO	25
2.3.6 FERRAMENTAS DE MONITORAÇÃO DA REDE PROFIBUS	25
2.4 CONCLUSÃO	27
3 REDES NEURAIS ARTIFICIAIS	29
3.1 INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS	29
3.1.1 NEURÔNIOS BIOLÓGICOS VS. NEURÔNIOS ARTIFICIAIS	31

3.1.2	ARQUITETURA DAS REDES NEURAIAS	33
3.2	PERCEPTRON MÚLTIPLAS CAMADAS	35
3.3	O USO DE SISTEMAS INTELIGENTES PARA CLASSIFICAÇÃO DE SINAIS.....	37
3.4	CONCLUSÃO	48
4	CLASSIFICAÇÃO DE SINAIS DE REDES PROFIBUS DP	49
4.1	ENSAIO 1 – DADOS COM SINAIS SINTETICAMENTE PRODUZIDOS	49
4.2	ENSAIO 2 – DADOS REAIS.....	58
4.2.1	COLETA DAS AMOSTRAS	61
4.2.2	ANÁLISE DOS SINAIS REAIS	63
4.2.3	TREINAMENTO E VALIDAÇÃO DA RNA.....	67
4.3	ENSAIO 3 – DADOS REAIS PRÉ-PROCESSADOS.....	69
4.3.1	ORGANIZAÇÃO DAS RNAS.....	71
4.3.2	RESULTADOS	74
4.4	CONCLUSÃO	76
5	CONCLUSÕES	77
	APÊNDICE A.....	85
	APÊNDICE B	88

1 Introdução

A evolução das redes de comunicação em ambientes industriais vem tornando cada dia mais viável a utilização de serviços que propõem a otimização de sistemas de processos.

Devido à tendência de padronizar as tecnologias de comunicação em ambientes industriais, vários protocolos de redes foram desenvolvidos ao longo dos anos e alguns deles fazem parte de um conceito chamado “*fieldbus*” ou redes de campo no idioma português. De acordo com SHOSHANI (et. al. 2010) o *Fieldbus* é uma tecnologia de infra-estrutura de rápido crescimento para automação e controle de campo. Essa tecnologia é regida por normas que permitem a liberdade de escolher e poder para integrar dispositivos de campo, cabos e *hosts*. Já THOMESSE (2005) diz que a tecnologia *Fieldbus* representa um domínio amplo de problemas que são semelhantes. Além disso, envolve uma variedade de soluções e técnicas que, embora freqüentemente vistas como intimamente relacionadas, são diferentes umas das outras.

Atualmente diversos tipos de *fieldbuses* podem ser empregados no projeto de sistemas de automação. Este trabalho está focado nos *fieldbuses* da família Profibus, mais especificamente no Profibus DP. Detalhes sobre esta tecnologia são apresentados na Seção 1.

Sabe-se que os *fieldbuses* apresentam diversas vantagens quando comparados às instalações “ponto a ponto” tradicionais entre equipamentos de automação. As principais delas são a redução nos custos com cabeamento, facilidade de manutenção, maior flexibilidade no *layout* e design do sistema e facilidade de expansão futura.

Porém, essas redes apresentam certa sensibilidade a falhas relacionadas à sua instalação. Problemas como cabeamentos longos e excesso ou falta de terminadores no barramento, por

exemplo, podem afetar as características da rede, alterar a impedância da linha e degradar o sinal que está sendo transmitido.

Para a detecção desses problemas, existem ferramentas de monitoramento da rede, que possibilitam o diagnóstico em caso de falha. Essas ferramentas apresentam e registram o tráfego de dados na rede, e permitem observar-se o desempenho da comunicação entre as estações Profibus para fim de diagnóstico o diagnóstico tanto na Camada Física quanto na Camada Enlace destas redes. Uma dessas interfaces voltada à camada Física é o osciloscópio, com as formas de ondas digitais de comunicação em tempo de operação. A operação normal da rede, assim como os possíveis problemas, possuem, cada um deles, uma forma de onda característica. Essas formas de onda são analisadas por um especialista responsável por avaliar a real situação da rede (norma, anormal, estável, instável). Esse processo de análise pode ser demorado e a interpretação das formas de onda pode não ser precisa.

Com a perspectiva de colaborar com um procedimento de diagnóstico que seja rápido e preciso ao mesmo tempo, de forma a se minimizar o tempo de parada de uma planta e possíveis prejuízos no processo, esta dissertação propõe uma técnica inteligente de análise e classificação de sinais digitais Profibus baseada em Redes Neurais Artificiais (RNA). Essa técnica atuará na verificação do sinal elétrico (camada Física), diretamente no barramento em tempo de operação avaliando e classificando formas de ondas geradas em algumas situações típicas de sistemas Profibus (situação normal ou com problemas).

Com tal objetivo definido, foram realizados estudos sobre RNAs e métodos de pré-processamento do sinal, com o objetivo de escolher a combinação que melhor se adequa a solucionar esse problema de classificação de sinais. As formas de ondas usadas para estudo foram colhidas no Centro de Competência Profibus do Brasil (CCP), localizado na Escola de Engenharia de São Carlos, USP e, usadas para treinamento e validação das RNAs.

Destaca-se, por fim, que tal objetivo se caracteriza como contribuição original na área em que se insere, baseando-se na ausência de ferramentas de engenharia e estudos científicos que realizam tal operação.

1.1 Objetivos

O objetivo desta dissertação é, através do uso de RNA do tipo Perceptron Múltiplas Camadas (PMC), propor uma técnica para classificar os sinais oriundos de uma rede Profibus DP.

Este objetivo pode ser subdividido em algumas metas:

- 1 – Definir arquiteturas para RNA (números de camadas intermediárias, números de neurônios) e selecionar a de melhor resultado;
- 2 – Validar a técnica proposta em sinais sinteticamente produzidos;
- 3 – Testar a técnica proposta em sinais Profibus reais, colhidos em uma rede especialmente configurada em laboratório.

Este trabalho faz parte de um projeto de doutorado que está sendo desenvolvido por MOSSIN (2012). As técnicas testadas e apresentadas neste trabalho serão implementadas por MOSSIN (2012).

1.2 Organização do trabalho

O Capítulo 2 apresenta uma descrição sobre o protocolo Profibus DP a fim de explanar pontos que serão explorados nos capítulos posteriores. O Capítulo 3 apresenta uma descrição sobre a RNA utilizada no trabalho e uma revisão bibliográfica sobre o uso de redes neurais para

reconhecimento de sinais. O Capítulo 4 descreve os experimentos e os resultados obtidos durante a pesquisa. No Capítulo 5 são apresentadas as conclusões do trabalho.

2 Protocolo Profibus

Considerando que este trabalho aborda diagnóstico de Redes Profibus, este capítulo introduz conceitos relacionados a este protocolo, principalmente os relacionados à camada Física.

O Profibus é um dos protocolos que fazem parte do grupo dos “*fieldbuses*” abertos e independentes de fornecedores (não-proprietários), que permitem, portanto a integração de equipamentos de diversos fabricantes em uma mesma rede.

A partir da década de 90 a questão da padronização para as redes industriais começou a ser solucionada com a adoção das primeiras normas técnicas por institutos de normalização. Essa foi uma das principais conquistas do setor, pois proporcionou principalmente a interoperabilidade entre os diversos equipamentos de uma planta industrial (VENTURINI, 2008).

A história do Profibus começou em 1987, na Alemanha, quando 21 companhias e institutos uniram forças e criaram um projeto estratégico *fieldbus*. O objetivo era a realização e estabilização de um barramento de campo bitserial, sendo o requisito básico a padronização da interface de dispositivo de campo (CASSIOLATO et. al., 2009).

Em 1993, foi desenvolvido o Profibus DP, que possuía a característica de ser mais rápido e mais configurável. Hoje, este protocolo está disponível em 3 versões: DP-V0, DP-V1 e DP-V2.

Baseado nestes dois protocolos de comunicação, acoplado com o desenvolvimento de numerosos perfis de aplicações orientadas e um número de dispositivos de crescimento rápido, o Profibus começou seu avanço inicialmente na automação de manufatura e, desde

1995, na automação de processos (Profibus PA). Como já indicado em outros pontos dessa dissertação, é importante destacar que o presente trabalho tem o seu foco na tecnologia Profibus DP e, no próximo item serão apresentados detalhes de sua arquitetura.

O padrão Profibus atende às exigências da norma IEC61158 e EN50170 e, conta com 3 tipos de tecnologias: Profibus DP, Profibus PA e Profibus FMS (este último foi descontinuado e vem sendo substituído pela tecnologia PROFINET). Devido a características técnicas, o Profibus DP pode substituir as redes convencionais HART® e 4-20 mA em sistemas de automação de processo e também os sinais discretos de campo em automação da manufatura.

Segue no texto uma descrição resumida de cada um dos três protocolos citados anteriormente:

- **Profibus DP:** Foi desenvolvido para operar com uma alta velocidade e conexão de baixo custo, e é utilizado na comunicação entre sistemas de controle de automação e seus respectivos I/O's distribuídos no nível de dispositivo. Pode ser usado para substituir a transmissão de sinal em 24 V em sistemas de automação de manufatura assim como para a transmissão de sinais de 4 a 20 mA ou HART® em sistemas de automação de processo (NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998).

- **Profibus FMS:** é o perfil de comunicação universal para tarefas de comunicação complexas, por exemplo, comunicação entre mestres. Oferece muitas funções sofisticadas de comunicação entre dispositivos inteligentes. Esta tecnologia está descontinuada e vem sendo substituída pelo PROFINET e, no futuro, com o uso do TCP/IP no nível de célula, o FMS terá um papel menos significativo (NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998).

- **Profibus PA:** Esta tecnologia define, em adição às definições padrões do Profibus DP, os parâmetros e blocos de função para dispositivos de automação de processo, tais como

transmissores, válvulas e posicionadores (NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998). O Profibus PA possui uma característica adicional que é a transmissão intrinsecamente segura, o que faz com que ele possa ser usado em áreas classificadas, ou seja, ambientes onde existe o perigo de explosão. É indicado por controlar variáveis digitais em linhas de produção seriada ou células integradas de manufatura. Encontrado predominantemente nas indústrias de transformação (NETO, 2008).

O Profibus é um sistema dito multimestre e permite a operação conjunta de equipamentos ou controladores terminais de engenharia ou visualização, com seus respectivos periféricos. Os Dispositivos Mestres determinam a comunicação de dados em um barramento. Essa comunicação é realizada enquanto o dispositivo mestre possui o direito de acesso ao barramento (*token*). O *token* é um mecanismo de arbitragem que deve ser implementado para evitar possíveis colisões no barramento quando mais de uma estação deseja transmitir uma mensagem (STEMMER, 2001). Os mestres são chamados de estações ativas no barramento. Já os Dispositivos Escravos são dispositivos de periferia como, válvulas, módulos de I/O, posicionadores, transmissores etc. Esses periféricos não possuem direito de acesso ao barramento, e somente enviam ou reconhecem alguma informação do mestre quando for solicitado.

2.1 Arquitetura das Redes Profibus

A arquitetura da rede Profibus é baseada em protocolo de rede que segue o modelo ISO/OSI.

A camada 1 inclui o meio físico onde a mensagem é transportada, tipicamente um cabo blindado de par trançado. Acima da camada 7 está a funcionalidade “real” do instrumento

tal como medição, atuação, controle ou a interface de operação de um configurador (BERGE, 2002). Este modelo pode ser visualizado na Figura 2. 1.

Figura 2. 1 - Modelo de Referência ISO/OSI aplicado à Rede Profibus

FONTE: BERGE (2002)

No Profibus DP são utilizadas as camadas 1 e 2 e também a Interface do Usuário. Já no Profibus PA e FMS, além dessas, a camada 7 também é utilizada. Essa arquitetura simplificada garante uma transmissão de dados eficiente e rápida. Considerando que será desenvolvida uma ferramenta que atuará na Camada Física, esta será descrita com mais detalhes na Seção 4.

2.2 Camada Física

A Camada Física do Profibus DP, que é amplamente explorada nesta dissertação, descreve a tecnologia de transmissão dos dados, a pinagem dos conectores e os parâmetros técnicos e elétricos que devem ser cumpridos (TECHNICAL GUIDELINE, 1998). É nesta camada que ocorre o transporte dos dados representados por um conjunto serial de bits entre dois equipamentos terminais (TANEMBAUM et al, 2002), via um suporte de transmissão, que pode ser os meios físicos RS-485 ou fibra ótica. A camada Física não interpreta os dados;

ela somente passa os dados para a Camada de Enlace (BERGE, 2002). Esta pesquisa emprega o meio físico RS-485 para estudo.

O RS-485 definido no Profibus DP codifica dados utilizando a técnica *Non-return Zero* (NRZ). Este tipo de codificação é a forma mais comum e mais utilizada para se transmitir sinais digitais, já que ela usa dois níveis de tensão diferentes para os dois dígitos binários, ambos diferentes da tensão nula [STALLINGS, 1997]. De acordo com a norma EN50170, este método procura assegurar que as transmissões ocorram somente quando sucessivos bits de dados possuam valores iguais. Um exemplo deste tipo de codificação pode ser visualizado na Figura 2. 2. Os dados codificados em NRZ são transmitidos por um cabo de par trançado. O bit “1” representa uma tensão diferencial positiva constante entre os pinos 3 (RxD/TxD-P) e 8 (RxD/TxD-N) do conector e o bit “0” representa uma tensão diferencial negativa constante. No RS-485 esses dados são transmitidos por dois condutores, denominados A e B, que transmitem níveis de tensão iguais, porém com polaridades opostas (V_A e V_B). Por esta razão, é importante que a rede seja ligada com a polaridade correta. Embora os sinais sejam opostos, um não é o retorno do outro, ou seja, não existe um *loop* de corrente. Cada sinal tem seu retorno pela terra ou por um terceiro condutor de retorno, entretanto, o sinal deve ser lido pelo receptor de forma diferencial sem referência a terra ou ao condutor de retorno.

Figura 2. 2 - Codificação NRZ

Pode-se notar na Figura 2. 3 que este sinal trafega com fases invertidas nos condutores do cabo enquanto o ruído trafega com mesma fase. Nos terminais de entrada do amplificador diferencial, o sinal de comunicação chega em modo diferencial e o ruído em modo comum, dá-se portanto a rejeição do ruído. Sendo assim, todo ruído que for induzido no cabo, em geral de origem eletromagnética, será em sua maioria rejeitado. Linhas de transmissão diferenciais utilizam como informação apenas a diferença de potencial existente entre os dois condutores do par trançado, independente da diferença de potencial que eles apresentam em relação ao referencial de tensão (comum ou terra). Isto permite que múltiplos sistemas se comuniquem mesmo que uma referência de potencial comum entre eles não seja estabelecida. No entanto, os circuitos eletrônicos de transmissão e recepção podem ser danificados se o par trançado apresentar um potencial excessivamente elevado em relação ao referencial (comum ou terra).

Figura 2. 3 - Exemplo de um Sinal Diferencial com Ruído

Considerando este tipo de sinal, segue um exemplo de um sinal típico na Figura 2. 4. Tal figura apresenta em sua parte superior a representação teórica da transmissão de um byte Profibus diferencial enquanto que em sua parte inferior, é apresentado um caractere real obtido a partir de um osciloscópio medido entre A e B. O byte da representação teórica não corresponde ao byte da representação real.

Figura 2. 4 - Caracter Profibus DP

Nota-se através da Figura 2. 4 que um caractere da Camada Física Profibus DP possui 11 bits, sendo o primeiro denominado como *Start* bit, os 8 seguintes como bits de dados, o décimo como bit de paridade (par) e o décimo primeiro e último como *Stop* bit. Cada sequência de informação é apresentada nesta forma, e a mensagem como um todo é reconstituída no destino final.

Como mencionado anteriormente, a escolha do meio físico e sua correta instalação são muito importantes para o bom desempenho da rede. Baseado nisto, este tópico será abordado com mais detalhes logo abaixo.

1) Meio físico

Cada aplicação da rede Profibus é influenciada pela escolha do meio físico. Os requisitos gerais, como alta confiabilidade de transmissão, grandes distâncias a serem cobertas e alta velocidade de transmissão somam-se às exigências específicas de cada área de automação do processo, como operação em áreas classificadas, transmissão de dados e alimentação dos instrumentos diretamente pelo barramento de dados, entre outras

(NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998). Devido a este fato, não é possível usar um único meio físico em todo o processo. Sendo assim foram desenvolvidos 3 tipos físicos que atendem às várias particularidades do sistema. São eles: RS-485, IEC61158-2 e Fibra Ótica. Segue abaixo uma descrição resumida de cada um destes meios de transmissão:

- RS-485: para uso universal, em especial em sistemas de automação da manufatura;
- IEC61158-2 ou Manchester Bus Powered (MBP): para aplicações em sistemas de automação em controle e processos;
- Fibra Ótica: para aplicações em sistemas que demandam grande imunidade à interferência e grandes distâncias (Profibus Descrição Técnica, 2011).

Conforme citado no Capítulo 1 este trabalho será implementado com foco na resolução de problemas do Profibus DP e no meio de transmissão RS-485. Este meio de transmissão foi escolhido devido ao fato de este ser o meio físico mais difundido e sensível dentre os existentes em redes Profibus.

a) RS-485

O RS-485 é o meio de transmissão mais utilizado no Profibus DP, pois apresenta como características principais altas taxas de transmissão e instalação simples e barata. Este meio físico usa como transporte dos dados um cabo de par trançado e blindado e permite que até 32 estações sejam conectadas ao barramento. Porém, o uso de repetidores é permitido, o que permite que uma rede se estenda a até 126 estações.

Os cabos usados nas instalações Profibus DP e recomendados pela norma EN 50170 (NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998), apresentam as seguintes características:

- Área do Condutor: maior que 0,34 mm²
- Impedância: 135 a 165 Ohms;
- Capacitância: menor que 30 pF;
- Resistência Específica: 110 Ohms/km;
- Medida do Diâmetro do Cabo: 0,64 mm;

O comprimento máximo de cada lance de cabo na rede varia de acordo com a velocidade de transmissão especificada para a rede, devendo ser totalizado considerando eventuais derivações. No caso do Profibus DP, essas derivações devem ser evitadas para *baudrate* maior ou igual a 3 Mbps (NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998). Segue na Tabela 2. 1 os comprimentos de segmento baseados nas respectivas velocidades de transmissão e o máximo comprimento das derivações.

Tabela 2. 1 - Comprimento Máximo de Cabo por Segmento

FONTE: (TECHNICAL GUIDELINE, 1998)

Taxa de Transferência (Kbps)	9,6	19,2	45,45	93,75	187,5	500	1500	3000	6000	12000
Comprimento Máximo de Segmento (m)	1200	1200	1200	1200	1000	400	200	100	100	100
Comprimento Máximo das Derivações (m)	500	500	500	100	33	20	6,6	-	-	-

É importante ressaltar também que os cabos de comunicação da rede devem manter uma certa distância de fontes que possam causar qualquer tipo de interferência no sinal. Além de mantê-los separados, é aconselhável utilizar bandejamentos ou calhas metálicas fechadas e aterradas, observando as distâncias conforme Tabela 2. 2. O ideal é utilizar canaletas de alumínio, onde se tem a blindagem eletromagnética externa e interna. O cruzamento entre os

cabos deve ser feito em ângulo de 90° (Profibus Installation Guideline for Cabling and Assembly, 2006).

Tabela 2. 2 - Distâncias Mínimas de Separação entre Cabeamentos

FONTE: Profibus Installation Guideline for Cabling and Assembly (2006)

	Cabo de Comunicação Profibus	Cabos com e sem shield: 60 Vdc ou 25 Vac e < 400 Vac	Cabos com e sem shield: > 400 Vac	Qualquer cabo sujeito a exposição de raios
Cabo de Comunicação Profibus	-	10 cm	20 cm	50 cm
Cabos com e sem shield: 60 Vdc ou 25 Vac e < 400 Vac	10 cm	-	10 cm	50 cm
Cabos com e sem shield: > 400 Vac	20 cm	10 cm	-	50 cm
Qualquer cabo sujeito a exposição de raios	50 cm	50 cm	50 cm	-

De acordo com a NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA (1998), se um cabo par trançado blindado é utilizado, a blindagem deverá ser aterrado em ambas as terminações do cabo via conexões de baixa impedância. Isto é necessário para se alcançar uma razoável blindagem eletromagnética. É altamente recomendável que a conexão entre o cabo blindado e o terra seja feito por uma canaleta metálica e parafusos de fixação metálicos do conector.

O cabo é conectado aos equipamentos através de conectores. Estes conectores são disponibilizados com algumas variedades de classes de proteção e projetos mecânicos. A escolha do melhor tipo de conector varia de acordo com a necessidade da instalação, porém o mais recomendado pela norma é o conector Sub-D com 9 pinos. Os pinos 3, 5, 6 e 8 são sempre utilizados. Os demais pinos são opcionais. Estes conectores em geral apresentam grau

de proteção IP20¹ (PROFIBUS INSTALLATION GUIDELINE, 2006). A Tabela 2. 3 mostra a descrição dos pinos do conector Sub-D com 9 pinos e na Figura 2. 1 é mostrado um exemplo deste tipo de conector.

Tabela 2. 3 - - Pinagem do Conector Sub-D com 9 Pinos

FONTE: (TEST SPECIFICATION FOR PROFIBUS DP SLAVES, 2004)

Número do Pino	RS-485	Sinal	Função
1		Shield*	Blindagem/terra de proteção
2		M24	Terra para tensão de saída de 24V
3	B/B'	RxD/TxD-P	Linha de envio e recebimento de dados – Positivo
4		CNTR-P**	Sinal de controle do repetidor, Sinal <i>Request to Send</i> (RTS)
5	C/C'	DGND	Potencial de referência de dados
6		VP	Fonte de alimentação – Positivo
7		P24V*	Tensão de Saída – 24 V
8	A/A'	RxD/TxD-N	Linha de envio e recebimento de dados – Negativo
9		CNTR-N**	Sinal de controle do repetidor

*Sinais opcionais;

**Sinais opcionais; preferencialmente nível de sinal RS-485

Figura 2. 5 - Pinagem do Conector Sub-D com 9 Pinos

FONTE: PROFIBUS INSTALLATION GUIDELINE (2006)

Em áreas onde se exige um grau de proteção maior, são disponíveis os conectores do tipo M12 com 5 pinos, que oferecem grau de proteção IP65/67² (PROFIBUS INSTALLATION GUIDELINE, 2006). Veja na Figura 2. 6 a descrição dos pinos do conector M12.

¹ O grau de proteção (IP) é a proteção oferecida por um invólucro contra a penetração de objetos sólidos (pó) e/ou penetração de água em partes perigosas do circuito eletrônico (CEI/IEC 60529, 2001). O primeiro dígito indica a proteção contra sólidos e o segundo a proteção contra líquidos. Neste caso, o dígito 2 indica que o invólucro do conector oferece proteção contra sólidos de diâmetro até 50 mm e maior e o dígito 0 indica que ele não é protegido contra entrada de água.

² No caso do grau de proteção IP65/67, o dígito 6 indica que o invólucro do conector é totalmente protegido contra sólidos. Já os dígitos 5 e 7 representam proteção contra jatos de água e imersão contínua em água, respectivamente.

Figura 2. 6 - Conector M12 com 5 Pinos

FONTE: PROFIBUS INSTALLATION GUIDELINE (2006)

Os conectores Sub-D com 9 Pinos apresentam em sua estrutura os terminadores de barramento. Esses terminadores são indispensáveis e é necessário que sejam habilitados dois terminadores no barramento, um no início e outro no fim de cada segmento. A terminação ativa na posição incorreta faz com que, tanto o nível quanto a forma de onda sejam degradados.

A ausência de terminadores nas extremidades do barramento pode causar erro na transferência de dados, devido reflexões no sinal que chega ao fim do barramento, fazendo com que este sinal volte pela linha de dados e se sobreponha ao sinal que está sendo enviado. Já o excesso de terminadores habilitados pode causar intermitência nos dados transmitidos fazendo com que ocorram interrupções na comunicação. Na Figura 2. 7 são apresentados os detalhes de uma conexão entre o cabo Profibus e um terminador e na Figura 2. 8 é mostrado um exemplo de uma rede Profibus utilizando-se repetidores e terminadores.

Figura 2. 7 - Exemplo de Cabo com Terminação

FONTE: (PROFIBUS INTERCONNECTION TECHNOLOGY, 2007)

Figura 2. 8 - Exemplo de uma Rede com Terminadores de Barramento e Repetidores

FONTE: (TECHNICAL GUIDELINE, 1998)

É importante ressaltar que a habilitação dos terminadores varia de acordo com a topologia da rede. Analisando-se a Figura 2. 8, pode-se concluir que:

- Segmentos 1 e 2: estes segmentos possuem uma topologia do tipo Barramento. Neste caso, é necessário habilitar um terminador no início (no mestre) e um no final deste barramento (último escravo do segmento). O último escravo deve permanecer o tempo todo alimentado com no mínimo 9 V;
- Segmento 3: este segmento possui uma topologia do tipo Árvore. Neste caso, os terminadores devem estar localizados no primeiro escravo (o mais à esquerda do mestre) e no último (o mais distante).

2.3 Métodos de diagnóstico existentes

As redes Profibus, assim como outros *fieldbuses*, podem apresentar problemas na operação. Devido à necessidade de se encontrar rapidamente a falha e resolver esses problemas, o profissional pode contar com diversos métodos para diagnosticar e avaliar o desempenho de uma rede Profibus DP. Estes métodos abrangem a validação dos critérios de projeto, configuração e instalação da rede, verificação de versões de *firmware* e dos arquivos GSD (*General Slave Data*) e a verificação do meio físico (SILVA, 2008). O arquivo GSD é um *datasheet* eletrônico que especifica as características básicas do equipamento como, velocidade de comunicação e diagnóstico. Nas próximas Seções, alguns desses métodos serão apresentados, destacando-se os testes utilizando o osciloscópio, já que o foco do trabalho é a análise das formas de ondas dos sinais da rede.

Os métodos aqui apresentados que baseiam-se no diagnóstico da camada Física e Enlace são:

- Inspeção visual da rede;
- Testes com multímetro;
- Testes com *handhelds devices*;
- Testes com osciloscópio;

- Testes utilizando repetidores com diagnóstico;
- Ferramentas de monitoração da rede.

2.3.1 Inspeção visual

As redes Profibus apresentam a desvantagem de serem muito sensíveis a falhas em sua instalação. É muito importante que o projeto da rede seja bem implementado e realizado por profissionais devidamente qualificados para este tipo de trabalho, a fim de se evitar futuros transtornos.

Porém, de acordo com SILVA (2008), existem algumas condições geradoras de falhas que podem ser visualmente observadas com as seguintes verificações:

- Se as curvaturas existentes no cabo estão dentro de um raio mínimo recomendado pelo fabricante;
- Se o cabeamento possui comprimentos específicos de acordo com a velocidade de transmissão escolhida;
- Se a blindagem do cabo não está sendo vista de fora do conector e que esta esteja fazendo contato com a parte metálica interna existente no conector;
- Se a blindagem e os dispositivos estão aterrados nas extremidades do segmento de rede e que todos os dispositivos estejam energizados.
- Se todos os dispositivos estão endereçados corretamente.

As Figura 2. 9 e 2.10 mostram alguns exemplos de problemas detectáveis com uma simples inspeção visual.

Figura 2. 9 - Falta de Terra no Equipamento

FONTE: ALASMAR (et. al, 2008)

Figura 2. 10 - Blindagem sem Contato com o Conector

FONTE: ALASMAR (et. al, 2008)

2.3.2 Testes utilizando multímetro

Com o uso do multímetro pode-se detectar as seguintes falhas na rede:

- Curto-circuito entre as linhas de dados A e B;
- Curto-circuito entre as linhas de dados A e B e a blindagem do cabo;
- Inversão simples das linhas de dados A e B;
- Interrupção de uma das linhas de dados A e B;
- Interrupção na blindagem do cabo.

Além destes, pode-se determinar também o comprimento aproximado do segmento de rede. Para isso, é necessário conhecer a Resistência de *Loop* do cabo Profibus, que é uma medida de resistência por comprimento (Ohm/m). O comprimento $L_{segmento}$ em metros é determinado pela Equação 1.

$$L_{segmento} = \frac{R_{específica}}{R_{loop}} \quad (1)$$

$R_{específica}$ = Resistência de *Loop* Específica, dada em Ohm/km e fornecida pelo fabricante do cabo.

R_{loop} = é determinada através de um curto-circuito entre os conectores em uma das extremidades do cabo. Assim, mede-se a resistência entre os dois conectores na outra extremidade com um multímetro e aplicam-se os valores à seguinte fórmula (TECHNICAL GUIDELINE INSTALLATION GUIDELINE FOR PROFIBUS-DP/FMS, 1998):

$$R_{loop} = \frac{V_m * 1000}{C_{cabo}(m)} \quad (2)$$

Onde:

V_m = valor medido em Ohm;

C_{cabo} = comprimento do cabo tomado como referência em metro (m).

Para determinar o comprimento do segmento, é necessário se atentar para as seguintes condições:

- Os dispositivos Profibus não podem estar conectados ao segmento de rede;
- O cabo Profibus deve estar desenergizado;
- As terminações do barramento deverão estar desconectadas;

- Caso seja uma rede DP/PA, que contenham componentes como *couplers* ou Módulos de *Link Ótico* (OLM's), esses componentes deverão ser desconectados.

2.3.3 Teste utilizando dispositivos de mão

De acordo com PROFIBUS INSTALLATION GUIDELINE FOR COMMISSIONING (2006), os *handhelds devices* foram desenvolvidos para simplificar os procedimentos de testes em instalações Profibus. Esses equipamentos oferecem uma checagem da rede mais rápida que o multímetro, resultados claros e maiores possibilidades de diagnósticos. Verificando-se a linha de dados também é possível realizar medições e checagens nas estações Profibus.

Atualmente existem disponíveis no mercado três opções de *handheld devices*, que são similares em questão de funcionalidade e escopo, porém, se diferem na forma como são operados. São eles:

- BT200, da Siemens (www.ad.siemens.de/net);
- NetTest II, da Consoft (www.consoft.de);
- Bustest, da HMS Industrial (www.anybus.com).

A Tabela 2. 4 apresenta as funcionalidades destes equipametos.

Tabela 2. 4 - Características Funcionais dos Equipamentos de Mão

FONTE: Profibus INSTALLATION GUIDELINE FOR COMMISSIONING (2006)

Funções
Teste na Camada Física <ul style="list-style-type: none">• Curto-circuito entre as linhas de dados ou entre uma das linhas e o <i>shield</i>;• Rompimento de uma das linhas de dados (circuito aberto);• Rompimento do <i>shield</i> (circuito aberto);• Inversão das linhas de dados A e B;• Reflexões que podem causar erros*;• Checagem no número de terminadores habilitados;• Medição do comprimento do cabo instalado;• Medição da impedância no cabo**;• Defeito nos <i>plugs</i> Profibus**;• Defeito nas estações ativas**;• Detecção de <i>spurs</i>**;• Detecção de diferentes tipos de cabos no barramento**.
Teste na Interface RS-485 <ul style="list-style-type: none">• Driver RS-485 OK ou com defeito;• Teste na alimentação dos terminadores;
Funcionamento das Estações <ul style="list-style-type: none">• Obtenção da lista de programas operacionais;• <i>Live List</i> das estações Profibus;• Teste de ativação de estações Profibus individuais.
Funções Online (opcional)** <ul style="list-style-type: none">• Medição do tempo de ciclo do barramento;• Medição de nível;• Análise de sinal do barramento;• Detecção do <i>baudrate</i>;• Registro de eventos;• Estatística dos eventos;• Leitura de eventos de diagnósticos.
Diversos <ul style="list-style-type: none">• Interface RS-232 para conexão ao PC;• Criação de eventos via PC;• Operação com bateria.
Notas: * Disponível somente para BT200; ** Não disponível para BT200.

2.3.4 Teste utilizando o osciloscópio

O osciloscópio é muito utilizado no diagnóstico de redes Profibus, porém exigem experiência do usuário tanto para manusear o equipamento quanto para interpretar as formas de ondas apresentadas por ele. Essas formas de onda são obtidas através da medição entre as linhas de dados A e B. O Profibus utiliza as duas linhas de dados para transportar a informação, sendo que o sinal transmitido na linha B nada mais é que o sinal da linha A invertido.

Devido ao fato de o sinal ser diferencial, o ruído é gerado uniformemente em ambas as linhas. Portanto, quando se faz a diferença de um para o outro, o telegrama de dados é percebido sem as distorções. Veja na Figura 2. 11 um exemplo de sinal diferencial mostrado no osciloscópio.

Figura 2. 11 - Sinal Diferencial Mostrado em um Osciloscópio

As ferramentas apresentadas fornecem um diagnóstico da rede, através da análise de sua camada física. Porém, existem outras ferramentas disponíveis que, além de analisarem a

camada física, analisam também a camada de enlace, através dos telegramas gerados. Essas ferramentas são detalhadas abaixo.

2.3.5 Testes utilizando repetidores com diagnóstico

Esses repetidores são similares aos repetidores comuns, porém possuem a capacidade de monitorar os segmentos de rede a fim de detectar defeitos. De acordo com MITCHELL (2004), com este repetidor é possível encontrar os seguintes problemas na rede:

- Curto-circuito entre as linhas de dados A e B;
- Interrupção de uma das linhas de dados A e B;
- Ausência das terminações;
- Perda de conexões;
- Reflexões excessivas, mostrando a distância a partir do repetidor;
- Número de estações acima do permitido em um segmento;
- Distância muito grande entre as estações e o repetidor;
- Telegramas com mensagens de diagnósticos.

2.3.6 Ferramentas de monitoração da rede Profibus

Atualmente, além de todos os métodos de diagnósticos apresentados anteriormente, é possível também realizar análise de uma rede Profibus utilizando-se ferramentas avançadas de monitoração da rede. Essas ferramentas, em geral, são executadas em PC com o acessório de interface à rede (cabo/hardware) e são capazes de mostrar e registrar o tráfego de dados na rede e fornecer dados para que se possa mensurar o desempenho da comunicação entre as estações Profibus. Porém, a análise das informações registradas exige do operador experiência e conhecimento detalhado do protocolo Profibus e das interações entre Mestres e Escravos.

A Tabela 2. 5 resume algumas características principais das ferramentas apresentadas neste item. A primeira coluna desta tabela apresenta as ferramentas utilizadas para monitoramento avançado da rede e na segunda coluna são apresentados os respectivos fabricantes. A terceira coluna indica se a ferramenta possui ou não uma interface de osciloscópio. Caso presente, nessa interface é possível visualizar as formas de onda do sinal Profibus. Já a quarta coluna indica se a ferramenta apresenta uma interface de análise dos *frames* Profibus. Neste caso, ao invés de se analisar as formas de ondas, são analisados os telegramas de mensagens. A coluna nomeada *Live List* indica se o equipamento apresenta uma interface onde são listados todos os dispositivos que estão endereçados na rede Profibus. O campo Filtro para Mensagens permite a visualização apenas dos telegramas selecionados. Já na coluna Geração de Trigger é mostrado se o equipamento fornece a funcionalidade de se “trigger” um determinado dispositivo, possibilitando assim, que a forma de onda de um dispositivo específico seja separada da forma de onda da rede como um todo. E, por fim, no campo denominado Decodificação de Telegramas mostra os telegramas que foram capturados para análise.

Tabela 2. 5 - Características Principais das Ferramentas de Diagnóstico de Redes Profibus

Ferramenta	Fabricante	Osciloscópio	Análise de Frames Camada de Enlace	Live List	Filtro para Mensagens	Geração de Trigger	Decodificação de Telegrama
Profibus Tester	Softing	Sim	Sim	Sim	Sim	Sim	Sim
Profitrace	Procentec	Sim	Sim	Sim	Sim	Sim	Sim
BC-502-PB	Softing	Não	Não	Sim	Não	Não	Não
Profibus Scope	Trebing+Himsted	Não	Não	Sim	Não	Não	Não
PB-MASTER	Projeto Acadêmico	Sim	Não	Sim	Não	Não	Não
BR-Tool*	Projeto Acadêmico	Não	Não	Não	Não	Não	Não

*A ferramenta BR-tool (HÜSEMANN et. al. 2003) foi desenvolvida com o objetivo de armazenar os dados coletados em uma rede Fielbus para uso futuro. A captura dos dados é feita em tempo real, porém a análise dos dados é realizada caso seja necessária a observação dos dados em um determinado momento da operação da rede. Ela não fornece dados de diagnóstico.

2.4 Conclusão

Como exposto neste capítulo, existem diversos métodos de diagnóstico existentes, porém, em todos eles existe a necessidade de uma verificação dos dados por um especialista. Cada uma das formas de se diagnosticar problemas na rede Profibus DP apresentada é eficaz e fornece resultados exatos sobre o comportamento da rede Profibus. A tomada de decisão, todavia, é baseada na análise dos dados por um profissional.

3 Redes Neurais Artificiais

Neste capítulo será apresentado um breve histórico das RNAs, a comparação entre neurônio biológico e neurônio artificial, arquiteturas de rede, os conceitos relacionados à RNA utilizada para este projeto, a rede do tipo Perceptron Múltiplas Camadas (PMC) e uma revisão bibliográfica sobre o uso de redes neurais para reconhecimento de padrões. A PMC foi selecionada, inicialmente, por apresentar entre suas características, a possibilidade de se fazer reconhecimento de padrão, que nesta pesquisa significou o reconhecimento de sinais elétricos de uma rede Profibus DP e, por fim, conforme apresentado na Revisão Bibliográfica, este tipo de rede neural foi bastante utilizada para processamento de sinais variados, auxiliando, por exemplo, no diagnóstico de alguns tipos de diabetes e epilepsia, reconhecimento de gestos manuais e padrões faciais e detecção e diagnóstico de falhas em processos produtivos. Em todos estes trabalhos a PMC apresentou resultados satisfatórios.

3.1 Introdução às Redes Neurais Artificiais

As RNAs, que serão muito importantes no desenvolvimento deste projeto são definidas por SILVA et. al. (2010) como:

[...] modelos computacionais inspirados no sistema nervoso dos seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo as mesmas representadas aqui por vetores/matrizes de pesos sinápticos.

Resumindo, as RNAs consistem em modelos computacionais que apresentam seu funcionamento baseado no comportamento do cérebro humano. De acordo com

FERNANDES (2009), o cérebro humano possui um sistema de processamento da informação extremamente complexo, não-linear e paralelo; ao passo que as redes neurais artificiais possuem um processamento paralelo que é distribuído pelas suas unidades de processamento, ou seja, os neurônios, que por sua vez são favoráveis ao armazenamento de conhecimento, de forma a disponibilizá-lo para uma posterior utilização.

Os primeiros estudos em RNA se iniciaram em 1943, quando o psiquiatra e neuroanatomista Warren McCulloch e o matemático Walter Pitts se uniram para realizar uma modelagem matemática que representasse o neurônio biológico. Porém, este trabalho se concentrou em descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais, deixando de lado as técnicas que deveriam ser utilizadas para o aprendizado da rede.

As formas de aprendizado começaram a ser estudadas com detalhes anos mais tarde, em torno de 1949, por Donald Hebb. De acordo com ANTONIO (2000), Hebb mostrou como a eficiência da aprendizagem de redes neurais é conseguida através da variação dos pesos de entrada dos nodos. Foi proposta uma teoria, conhecida como Regra de Hebb, que explicava o aprendizado dos nodos biológicos baseada no reforço das ligações sinápticas entre os nodos excitados.

Anos mais tarde, os pesquisadores Widrow e Hoff desenvolveram a Regra Delta, que ainda hoje é bastante utilizada no aprendizado das RNAs. Esta regra é baseada no método do gradiente e faz a minimização do erro na saída do neurônio como resposta linear.

Em 1958, Frank Rosenblatt apresentou um novo modelo de aprendizagem, conhecido como Perceptron. De acordo com FERNANDES (2009), o modelo de Rosenblatt constituía-se de uma RNA baseada no neurônio artificial proposto por McCulloch e Pitts, porém, com algoritmo de treinamento que fazia uso dos pesos de entrada ajustáveis como demonstrado por Hebb. Uma desvantagem deste método é que o Perceptron apenas classifica padrões que

sejam linearmente separáveis, ou seja, problemas cuja solução pode ser obtida através da divisão do espaço de entrada em duas regiões através de uma reta (BRAGA et. al, 2000).

Baseada nessa deficiência, os pesquisadores Minsky e Papert apontaram para o problema do crescimento explosivo, tanto de espaço ocupado como do tempo requerido para a solução de problemas complexos, que afetaria, cedo ou tarde, as RNAs, inclusive o Perceptron (BRAGA et. al, 2000). Devido a esta questão, os estudos nesta área ficaram adormecidos, apesar de alguns poucos pesquisadores terem continuado suas pesquisas. Foi quando, em 1982, John Hopfield publicou um artigo, resultado de suas pesquisas em propriedades associativas de RNAs. Seus estudos mostraram a relação entre redes recorrentes auto-associativas e sistemas físicos e a partir daí, outros fatores também influenciaram a retomada aos estudos em RNA, de forma que nos dias atuais, várias áreas vêm conseguindo avanços significativos na resolução de alguns problemas simples para o ser humano.

Uma das áreas onde se empregam estudos em RNAs são para reconhecimento de sinais. Esses estudos vêm sendo usados há alguns anos e vem ganhando respeito devido ao sucesso de seus resultados.

3.1.1 Neurônios biológicos vs. neurônios artificiais

O modelo de neurônio artificial proposto por McCulloch e Pitts foi baseado no que se sabia sobre o neurônio biológico, que se divide em três partes: o corpo da célula, os dentritos e o axônio, cada um destes contendo suas funções específicas.

No neurônio biológico, os dentritos possuem a função de receber as informações e conduzi-las ao corpo celular. Neste ponto as informações são processadas e novos impulsos são gerados. De acordo com BRAGA (2000), estes impulsos são transmitidos a outros neurônios, passando pelo axônio até chegarem aos dentritos do neurônio seguinte. O ponto de

encontro entre o axônio e o dentrito é chamado de sinapse, e é através destas sinapses que os nodos se unem formando as redes neurais.

De forma análoga os neurônios artificiais foram elaborados para seguirem a mesma estrutura física dos neurônios biológicos, ou seja, foi constituído um modelo com 'n' terminais de entradas ($x_1, x_2, \dots, x_n$) que representam os dentritos e apenas um terminal de saída, que representa o axônio. Para representar as sinapses, foram criados os pesos sinápticos que são usados para determinar em que grau o neurônio deve considerar sinais de disparo que ocorrem em uma determinada conexão.

O projeto de uma RNA é dividido em duas partes: treinamento e validação das informações. Durante a etapa de treinamento a rede recebe um conjunto de dados. Esses dados são usados no aprendizado da rede, que assim como o cérebro humano, aprende através de exemplos e associações e são nos seus neurônios que essas informações são armazenadas.

Uma comparação entre o neurônio biológico e o neurônio artificial é mostrada na Figura 3. 1.

Figura 3. 1 - Comparativo entre o Modelo de Neurônio proposto por McCulloch e Pitts e o Modelo de Neurônio Biológico

FONTE: FERNANDES (2009)

3.1.2 Arquitetura das redes neurais

A arquitetura da RNA é um fator importante a ser considerado no desenvolvimento do algoritmo computacional, pois é ela quem vai restringir o tipo de problema que poderá ser tratado pela rede.

A definição da arquitetura leva em consideração o número de camadas da rede (camada única ou múltiplas camadas), número de nodos em cada camada (quantidade de neurônios), o tipo de conexão entre os nodos (*feedforward* ou *feedback*) e a topologia da rede (rede parcialmente conectada ou totalmente conectada).

Outro fator importante para a escolha da arquitetura é a função de ativação de cada neurônio. As funções de ativação do neurônio são responsáveis pela produção de uma saída qualquer, não necessariamente zero ou um.

Veja abaixo os principais tipos de função de ativação e a equação que representa cada uma delas.

- Função Linear

$$f(x) = \alpha x \quad (3)$$

Figura 3. 2 - Função de Ativação do Tipo Linear

FONTE: SILVA et. al. (2010)

- Função Rampa

$$\left\{ \begin{array}{l} f(x) = 1, \text{ se } x \geq 1 \\ x, \text{ se } -1 < x < 1 \\ -1, \text{ se } x \leq -1 \end{array} \right. \quad (4)$$

Figura 3. 3 - Função de Ativação do Tipo Rampa

FONTE: SILVA et. al. (2010)

- Função Degrau Bipolar

$$\left\{ \begin{array}{l} f(x) = 1, \text{ se } x > 0 \\ -1, \text{ se } x \leq 0 \end{array} \right. \quad (5)$$

Figura 3. 4 - Função de Ativação do Tipo Degrau Bipolar

FONTE: SILVA et. al. (2010)

- Função Sigmoidal

$$f(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

Figura 3. 5 - Função de Ativação do Tipo Sigmoidal

FONTE: SILVA et. al. (2010)

3.2 Perceptron Múltiplas Camadas

As redes PMC são caracterizadas pelas diversas possibilidades de aplicações em diversos tipos de problemas, relacionados com diversas áreas do conhecimento (SILVA et. al. 2010). Diferente das redes *Perceptron*, essas redes possuem uma ou mais camadas intermediárias. De acordo com CYBENKO (1989), uma rede com uma camada intermediária pode implementar qualquer função contínua e a utilização de duas camadas intermediárias possibilita a aproximação de qualquer função. Neste trabalho foi utilizada uma PMC com apenas uma camada intermediária.

Outro fator importante é o tipo de treinamento que pode ser realizado pela PMC. Uma das possibilidades se baseia no gradiente descendente. De acordo com BRAGA (2000), a utilização deste método exige que a função de ativação seja contínua, diferenciável e, de preferência, não-decrescente. Também é importante definir qual é o tipo de função de

ativação que será utilizada pelos neurônios, pois ela é responsável por limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua imagem funcional (SILVA et. al., 2010).

Além dessas, como em todas as outras arquiteturas, elas possuem também uma camada de entrada e uma camada de saída. A camada de entrada se responsabiliza por receber os sinais vindos do processo, as camadas neurais intermediárias possuem a função de extração e armazenamento do conhecimento e a camada neural de saída emite uma resposta coerente ao estímulo dado na entrada da rede.

Veja na Figura 3. 6 um exemplo da arquitetura da rede PMC contendo uma única camada intermediária.

Figura 3. 6 - Exemplo de uma Rede PMC com uma Camada Intermediária

FONTE: Adaptado de SILVA et. al. (2010)

Como pode ser observado na Figura 20, nas redes do tipo PMC os neurônios de cada camada apenas são conectados aos neurônios da camada seguinte, não existindo qualquer outro tipo de conexão entre eles. Todo o conhecimento obtido pelo processamento dos

neurônios da camada intermediária será armazenado na forma de pesos sinápticos, representados por W_{1ji} e W_{2ji} (SILVA et. al. 2010).

3.3 O uso de Sistemas Inteligentes para classificação de sinais

As RNAs são treinadas e testadas para reconhecer variados tipos de padrões. Há anos elas vêm sendo usadas, entre muitas aplicações, para classificar o comportamento de processos industriais. O trabalho de NARENDRA (et. al. 1990), afirma que as RNAs poderiam ser usadas efetivamente na identificação e controle de sistemas dinâmicos não-lineares. Foi discutido um modelo de RNA onde duas arquiteturas eram interconectadas: uma rede MPL, com uma camada de entrada e uma de saída e duas camadas intermediárias e uma rede recorrente, ou Rede Hopfield. Foram realizados seis testes, onde cada um deles foi escolhido para enfatizar um ponto específico do trabalho. Nos cinco primeiros foi utilizado um modelo série-paralelo que tinha a função de identificar os dados da planta e o algoritmo de backpropagation foi utilizado para ajustar os parâmetros da RNA. O sexto exemplo é usado para indicar como o algoritmo backpropagation deve ser usado na identificação dos problemas. Apesar das diferenças existentes entre as duas abordagens para reconhecimento de padrão usando RNA, os resultados da simulação mostraram que essa combinação era possível e este método era aplicável.

No trabalho de NAIDU (et. al. 1990), é discutido o uso de RNA para detecção de falhas em sensores em um sistema de controle. Neste trabalho também foi utilizado o algoritmo de backpropagation para análise do sistema e detecção das falhas. A arquitetura da rede foi composta de uma camada de entrada, uma de saída e uma camada neural intermediária. O estudo realizado com essa arquitetura mostrou que este método de detecção de falhas apresentou-se (em 1990) como promessa significativa. As principais vantagens da metodologia proposta são a capacidade deste método de capturar as características não-

lineares, a possibilidade de treinamento online e possibilidade de implementação rápida feita de forma online também.

O trabalho de BECRAFT (1993) trata do uso de RNAs do tipo PMC com algoritmo de treinamento backpropagation para se realizar diagnósticos em aplicações industriais. Neste trabalho são apresentados dois estudos de casos que tratam da análise de sistemas de processos químicos. No primeiro caso, o objeto de estudo é um forno industrial e no segundo caso é estudada uma usina de destilação de multi-colunas. Em ambos os estudos, são analisados os dados de entrada e seus efeitos sobre as possíveis falhas que ocorrem nesses processos. No primeiro caso é examinado o uso de dados de entrada binários e trinários, o efeito de sintomas primário e secundário e a importância do diagnóstico para uma boa performance da rede. Como resultado obteve-se 97% de precisão tanto para análise dos dados binários quanto trinários. Já no segundo estudo de caso é examinado o uso de representações de dados de entrada de valores contínuos, uma rede neural hierarquicamente estruturada para realizar diagnósticos em grandes sistemas, o efeito do ruído nos dados de entrada para a performance da rede e a resolução das situações de falha. Neste caso o número de variável analisadas é muito maior que no primeiro caso devido ao fato de esta planta ser dividida em três colunas, o que fez com que o uso de uma RNA simples não fosse viável. Portanto, foi utilizada uma estratégia de diagnóstico hierárquico desenvolvida para reduzir a carga computacional das redes enquanto aumenta a eficácia potencial de diagnóstico para este caso. Assim, foram utilizados dois níveis de redes PMC para implementar a estratégia de diagnóstico. O primeiro nível é implementado na planta principal e o segundo é implementado nas três colunas de baterias, sendo uma RNA para cada bateria. Após os testes foi constatado que este esquema oferece um elevado grau de robustez à presença de ruído do sensor. A porcentagem de acerto no melhor caso chegou a 94%. Além disso, a estratégia hierárquica foi capaz de diagnosticar cenários com novas falhas.

Já no trabalho de WU (et. al. 2000) uma RNA do tipo PMC é utilizada para se fazer diagnóstico de falhas em linha mecânica de motor de indução. A RNA foi implementada com quatro camadas, ou seja, uma camada de entrada, duas camadas intermediárias e uma camada de saída. Como resultado obteve-se 100% de reconhecimento dos dados com falhas e 97,6% de reconhecimento dos dados considerados sem nenhum tipo de falha.

Em WU (et. Al. 2004) é utilizada uma RNA do tipo Função Base Radial (RBF) para se realizar análise e classificação de falhas em máquinas de indução. Neste trabalho, foram extraídos quatro vetores de características do sistema a partir de espectros de potência dos sinais de vibração da máquina. As características extraídas foram usadas como entradas da RBF e, esta RNA foi testada com dados de falhas elétricas, mecânicas e dados de situação normal da rede. Os resultados obtidos foram: 99,8% de reconhecimento dos dados da rede em condições normais, 96,5% de reconhecimento dos dados com falhas elétricas e 100% de reconhecimento dos dados de falhas mecânicas.

No estudo de AWADALLAH (et. al. 2003) falou-se sobre aplicação de ferramentas de inteligência artificial no diagnóstico de falhas em máquinas elétricas e drivers. O trabalho teve como objetivo realizar o monitoramento de condições que levam à falha. O diagnóstico correto e precoce de falhas resulta em manutenção programada e rápida resolução do problema em questão e também evita consequências nocivas para a máquina e possíveis prejuízos no processo. Os autores analisaram neste trabalho o uso de sistemas inteligentes, como RNA, Sistemas Fuzzy e Sistemas Fuzzy Adaptativo e Sistemas Especialistas para se fazer automação de procedimentos de diagnósticos. As RNAs foram utilizadas por apresentarem funções altamente não-lineares por fazerem mapeamento de múltiplas entradas e saídas. As principais funções executadas por elas foram: reconhecimento de padrão, estimativa de parâmetros, mapeamento não-linear aplicado às condições de monitoramento, previsão de falhas em estágios incipientes, condição de operação de agrupamento com base

em tipos de falhas etc. Os Sistemas Fuzzy criam uma base de dados baseado em regras “if-then” e o Sistema Fuzzy Adaptativo utilizam as capacidades de aprendizagem da RNA para ajustar o conjunto de parâmetros do sistema, a fim de melhorar o desempenho do sistema inteligente. Esses sistemas foram utilizados principalmente com a finalidade de avaliar índices de desempenho utilizando variáveis linguísticas, previsão de operação anormal e localização de elemento defeituoso, classificação de falhas e prognóstico etc. Por fim, os Sistemas Especialistas são capazes de tomar decisões em um nível de qualidade comparável a especialistas humanos. Neste estudo, as principais funções realizadas por esses sistemas foram: emulação e implementação de experiência humana, construção e bases de conhecimento online de atualização do sistema, classificação de falhas, diagnóstico e localização etc. O uso técnicas de Inteligência Artificial na detecção de falhas em processos industriais agiliza o diagnóstico e a tomada de decisão e está ampliando o horizonte de novas pesquisas relacionadas ao tema.

Em JAIN (et. Al. 2008) é utilizado um sistema especialista capaz de diagnosticar falhas em equipamentos de sistemas de potência. Isto é possível através de uma extensa coleta de dados por um engenheiro especialista na área. Esses dados se baseiam em histórico de ocorrência de falhas e livro de anotações sobre o que ocorre no campo. Os dados obtidos são colocados na base de conhecimento do sistema especialista em forma de regras “if-then” ou em forma de perguntas e respostas na tabela de banco de dados. Todos os dados coletados foram organizados em forma de tabelas contendo o nome do equipamento, sintomas, causas e medidas corretivas. Em seguida, foram transformados em árvore de decisão e por fim, em regras na base de conhecimento. Os equipamentos utilizados foram: transformadores, motores AC e DC e postes de luz.

Em Huang (et. Al. 2010) são utilizadas RNAs baseadas em genética (GNSS – *Genetic-based neural networks*) para detecção de falhas em transformadores de potência. As GNSSs

ajustam, automaticamente, os parâmetros da rede, os pesos de ligação e as condições de polarização das RNAs para se obter o melhor método de acordo com o algoritmo genético proposto. Além disso, podem identificar relações complexas entre o conteúdo de gás dissolvido em óleo do transformador e as falhas correspondentes. Foi observado que o uso de GNSSs apresentaram bons resultados relacionados à precisão do diagnóstico e da velocidade de aprendizagem das abordagens existentes, chegando a 95,08% de reconhecimento dos dados apresentados.

Em muitas pesquisas os dados analisados sofrem um pré-processamento do sinal antes que eles sejam carregados na RNA para que esta faça uma classificação sobre o processo. Em outras pesquisas não se usa pré-processamento. Com relação a esse processo de não se pré-processar os dados de entrada da RNA, o mesmo ocorreu no trabalho de MAKI (et. al. 1997), onde foi realizado um estudo utilizando-se uma RNA do tipo PMC para detectar e diagnosticar falhas em um processo produtivo. Este processo trata-se um reator de tanque continuamente agitado (*Continuously well-Stirred Tank Reactor* - CSTR), onde situações envolvendo perdas de calor desprezíveis, densidades constantes e misturas dentro do tanque eram assumidas. O trabalho tratou sobre as falhas que ocorriam em períodos transitórios de operação do tanque e, foi dividido em dois estágios, onde uma RNA foi utilizada em cada um deles. No primeiro estágio a rede detectava a tendência dinâmica de cada medição. Nesta etapa era realizada uma normalização dos dados, ajustando-os com valores na faixa de $[-1, 1]$ antes de iniciar o treinamento da RNA. Já no segundo estágio a rede detectava e diagnosticava a falha. Os dados de saída da primeira RNA foram utilizados como entrada da segunda.

Porém, para outras situações é necessário um pré-processamento do sinal antes de apresentá-lo à RNA. Alguns estudos mostram o uso de técnicas como PCA (Análise de Componentes Principais), Transformada de Fourier (Discreta e Rápida) e Transformada Wavelet, que são utilizadas para extrair dos dados suas principais características e diminuir a

dimensionalidade desses dados. O PCA é utilizado quando se analisa os sinais no domínio do tempo e as Transformadas de Fourier e Wavelet são utilizadas quando se analisa os sinais no domínio da frequência.

O uso de PCA como uma técnica de pré-processamento de sinais que serão classificados por RNA vem sendo cada dia mais utilizado em diversas áreas que envolvem desde reconhecimento de padrões relacionados ao corpo humano à classificação de sinais.

No trabalho de D'EMERY (2007), uma RNA foi utilizada no reconhecimento de sinais de odores utilizando-se nariz artificial, com o objetivo de se detectar um determinado tipo de diabetes, conhecido como *Diabetes Mellitus*. Os dados foram obtidos através da leitura de um sensor de aroma. Neste caso, o PCA foi utilizado para a extração das características dos sinais colhidos e redução da dimensionalidade dos dados e as redes neurais PMC e RBF foram utilizadas na classificação dos padrões. As redes neurais PMC e RBF obtiveram uma classificação de 77% e 66% para os dados normalizados sem a utilização de PCA, respectivamente. Porém, após o pré-processamento utilizando-se o PCA, o resultado da classificação atingiu 100%.

Já no trabalho proposto por LAMAR (et. al. 2003), foi utilizada uma RNA do tipo PMC no reconhecimento de posturas manuais, ou seja, reconhecimento de gestos. O método de extração dos dados é obtido baseado em uma luva colorida, usada para modelar a postura e posição da mão a partir de um sinal de vídeo. As posturas realizadas foram baseadas em gestos que representam os alfabetos japonês e português. Após a obtenção desses dados é feito um pré-processamento deles utilizando PCA, com o objetivo de se extrair as principais características das amostras. Em seguida, os dados pré-processados foram carregados na rede neural. Com o pré-processamento, a RNA obteve uma taxa de reconhecimento de 89,4% dos sinais que representavam o alfabeto japonês e 94,5% para os sinais que representavam o alfabeto português.

O trabalho proposto por MOUTINHO (et. al. 2003), trata sobre o reconhecimento de padrões faciais. Este trabalho tem como objetivo localizar e extrair de uma imagem completa, a face de uma pessoa, separando-a dos demais detalhes que contenham na imagem. O método de obtenção dos dados consiste no princípio de segmentação, que, segundo os autores, consiste em retirar da imagem original todos os retângulos possíveis e distintos, enviando-os ao módulo seguinte, redimensionados para um mesmo tamanho padrão, para serem entregues aos módulos de pré-processamento (PCA) e redes neurais, que no caso desta implementação, foi considerada a rede ADALINE. Neste trabalho, além do reconhecimento da face como um todo, também é realizado um reconhecimento de cada parte do rosto separadamente. A taxa de reconhecimento para cada um desses padrões ficou em torno de 90% para a face, 83% para os olhos, 68% para o nariz e 86% para a boca.

Uma abordagem da combinação entre PCA e RNA que difere das áreas apresentadas nos trabalhos acima é tratada no trabalho de LIRA (2004). Neste trabalho a autora propõe o uso destas técnicas para a classificação de sinais com distúrbio em sistemas de potência. Inicialmente foram desenvolvidos novos tipos de Wavelets que foram utilizadas para análise do sinal. Em seguida, esses sinais foram submetidos a um pré-processamento utilizando-se PCA, com o objetivo de reduzir a dimensionalidade dos dados. Finalmente, esses dados foram apresentados à uma rede neural do tipo PMC, para que esta indique qual é o tipo de distúrbio presente no sinal. A classificação média para todos os testes realizados foi de 94,4% de reconhecimento em todos os sinais apresentados.

No trabalho de PARISI (1998), foi realizado um experimento de reconhecimento de placas de carro. As imagens utilizadas nos testes foram tiradas em um pedágio e pré-processadas utilizando-se Transformada Discreta de Fourier (FDT). Os dados obtidos foram classificados utilizando-se uma RNA do tipo PMC. A mesma RNA utilizada para a extração de características dos dados, também foi utilizada para a classificação dos sinais. A

porcentagem de dados reconhecidos pela RNA foi satisfatória, o que mostra que essa arquitetura é confiável e o reconhecimento das placas pode ser realizado independente do estado físico delas, ou seja, se estão sujas, molhadas, apagadas etc.

Uma segunda abordagem para o uso de Transformada de Fourier (FT) é para reconhecimento de sons do coração. No trabalho de SHAMSUDDIN (2005), foram realizados experimentos com o objetivo de se classificar, através de uma RNA PMC, os possíveis sons que vem do coração e através dessa análise identificar o significado de cada uma das possíveis situações. Esse procedimento é realizado, na maioria dos casos, por médicos, que, através de um sistema de auscultação e de anos de experiência, especializou-se na identificação, apenas ouvindo, qual é o problema que o coração possa estar apresentando. Neste trabalho, os sons do coração foram colhidos utilizando-se válvulas cardíacas problemáticas e após a coleta esses dados foram digitalmente filtrados, segmentados e em seguida, reduzidos a uma estrutura arbitrária de 64 pontos. Por fim, foram pré-processados utilizando-se Transformada Rápida de Fourier (FFT) e carregados na RNA para que fosse feita a classificação. Para se testar a robustez da rede, foram utilizados sons com diferentes tipos de ruídos. O resultado dos testes foi satisfatório, com a RNA classificando corretamente 100% dos sinais apresentados.

No trabalho de HERNÁNDEZ (2008), a combinação entre FT e RNA foi utilizada para eliminar ruídos em ondas senoidais, triangulares e dente de serra. Este método foi baseado no uso de RNAs complexas capazes de eliminar ou diminuir o ruído nesses tipos de ondas. Este trabalho foi dividido em três etapas. Na primeira, foi formado um conjunto de treinamento composto por sinais sem ruídos e em diferentes fases. Esse conjunto foi utilizado para treinamento da rede. Em seguida, o conjunto de treinamento foi pré-processado utilizando-se FFT para se obter as componentes de frequência dos sinais. E, por fim, um conjunto de sinais ruidosos foi aplicado à RNA para simulação. A função da RNA é fazer

uma comparação entre os sinais de entrada e de saída e verificar a diferença existente entre eles. Para os casos de identificação dos sinais senoidais e triangulares, a rede se comportou de forma adequada, porém, no caso do reconhecimento de sinais dente de serra, o resultado obtido não foi satisfatório, pois a transição abrupta de amplitude dificultou o aprendizado da RNA.

O trabalho de KAMEL (et. al. 2009) mostra um estudo baseado em inteligência artificial com o objetivo de proteger linhas de transmissão em sistemas elétricos de potência. Este trabalho, que foi dividido em três partes, contou com estudos relacionados RNA e Lógica Fuzzy (denominado Sistema de Inferência Neuro-Fuzzy Adaptativo - ANFIS), que foi usado para detecção, classificação e localização da falha e, FT, utilizada para realizar um processamento digital dos sinais de tensão e corrente que eram usados na entrada do ANFIS. A primeira etapa consistiu em detectar a ocorrência da falha em um curto período de tempo e isolar a seção defeituosa da linha de transmissão. Na segunda etapa, foi realizada a classificação do tipo de falta e dedução de qual das três fases estavam expostas à falha. E, por fim, na última etapa era realizada a localização da falha. Esse esquema proposto apresentou um alto grau de satisfação, visto que, no pior caso, a rede obteve apenas 8% de erro na classificação dos sinais apresentados.

Em outros estudos, a FT foi utilizada para detecção, classificação e identificação de sinais, independente do uso de RNA. É o caso, por exemplo, do trabalho realizado por LALLO (1999), que apresentou um método de classificação de sinais usando FDT. Neste projeto foi avaliada a transmissão de dados digitais através de redes de telecomunicações e modulação digital dos canais de rádio. Este estudo mostrou como o método Transformada Discreta de Fourier pôde ser usado para propósitos de detecção, classificação e identificação de formas de ondas. Foram analisadas as taxas de transmissão, métodos de modulação do sinal, os símbolos transmitidos e a taxa usando-se diferentes frequências de amostragem com

FDT. Ao final da pesquisa o autor chegou à conclusão de que a FDT, até o momento da pesquisa, não havia sido usada neste tipo de aplicação devido à complexidade de implementação e o alto tempo gasto para o cálculo. Geralmente, é utilizado o método FFT para análises de sinais, porém, neste caso a FDT foi capaz de analisar com sucesso os sinais apresentados.

Uma outra forma de pré-processar sinais é utilizando-se Transformada Wavelet. No trabalho de AMINIAN (et. al. 2000) foi proposto um método de diagnóstico de falha em circuitos analógicos baseados em RNA, cujo método de pré-processamento utilizado foi a transformada de Wavelet. A RNA utilizada foi do tipo backpropagation. A RNA trabalha analisando a resposta de impulso do circuito eletrônico analógico e, através disso, consegue detectar e identificar falhas no sistema. Utilizando-se a transformada Wavelet como pré-processador do sinal de entrada e PCA para se fazer uma normalização dos dados, conseguiu-se diminuir drasticamente o número de entradas da RNA, simplificando a arquitetura e minimizando o tempo de processamento da rede e, conseqüentemente, conseguiu-se uma classificação de 100% dos dados analisados.

No estudo de GÜLER (et. al. 2005), utilizou-se uma rede neural baseada em wavelet para se detectar mudanças eletrocardiográficas em pacientes com epilepsia parcial. Este trabalho foi dividido em duas etapas. Na primeira foi realizada uma extração das características dos sinais cardíacos utilizando-se transformada wavelet e, na segunda, foi feita a classificação desses sinais usando-se uma RNA do tipo PMC, com algoritmo de treinamento backpropagation. Foram utilizados como dados de entrada, dois tipos de situações: sinais cardíacos considerados normais e sinais representando o problema de epilepsia parcial. Após o treinamento foi realizada uma comparação entre resultados da classificação, os valores dos parâmetros estatísticos e os parâmetros de avaliação de performance da RNA e, como resultado obteve-se uma variação de 90% a 97,5% de

reconhecimento dos dados apresentados, o que indica que a RNA se comportou de forma excelente e atingiu os objetivos esperados.

Ainda se tratando de diagnóstico de epilepsia, foi realizado um estudo por ORHAN (et. al. 2010), onde um sistema para classificação de sinal de eletroencefalograma (EEG) utilizando-se uma RNA do tipo PMC foi proposto. O método de pré-processamento dos sinais utilizados foi a Transformada de Wavelet Discreta (DWT). Neste trabalho foram analisadas cinco classes de dados, cada uma delas contendo 100 amostras de um exame de EEG. Foram utilizados como entrada da RNA a média, o desvio padrão e a entropia desses coeficientes. Foram realizadas duas diferentes classificações utilizando-se a mesma RNA. Na primeira foram classificados os dados dos exames de EEG de três tipos de pacientes: os saudáveis, os pacientes com epilepsia durante uma crise de convulsão e os pacientes com epilepsia em um intervalo livre de crises. Na segunda foram analisados os dados dos exames referentes apenas aos pacientes com epilepsia, em momentos com e sem crise. No primeiro teste obteve-se um resultado de 99,60% de reconhecimento dos dados analisados e, no segundo a rede conseguiu classificar 100% dos dados apresentados a ela. Como se pode observar, uma RNA do tipo PMC, se atende às expectativas esperadas para a análise deste tipo de sinal.

Já no trabalho de ANGRISANI (2001), foi realizado um estudo para se desenvolver uma arquitetura de processamento de sinal digital capaz de classificar e detectar, automática e simultaneamente, sinais transitórios. A unidade básica desta arquitetura é a rede *Wavelet*, que combina a capacidade da transformada wavelet na análise de sinais estacionários com a capacidade de classificação das redes neurais. No processo de classificação, dois ou mais transientes pertencem à mesma classe quando eles têm, aproximadamente, a mesma forma, o que difere da caracterização do transiente de outras classes. A entrada da RNA é uma sequência de amostras do sinal em teste, adquiridas em uma taxa de amostragem uniforme.

3.4 Conclusão

O uso de sistemas inteligentes para se classificar sinais é explorado em diferentes áreas do conhecimento. Essa técnica faz com que a análise dos dados seja feita de forma rápida e precisa e, necessita por vezes de técnicas de pré-processamento.

A RNA mais empregada é a PMC, que apresentou resultados satisfatórios em todos os estudos apresentados e o método de processamento mais utilizado, variou de acordo com o estudo que foi realizado, porém, todos os métodos mostrados nesta dissertação atenderam com eficiência a necessidade do projeto onde foram empregados.

4 Classificação de Sinais de Redes Profibus DP

Neste capítulo serão apresentados os aspectos relacionados à metodologia proposta para a classificação dos sinais Profibus DP. Serão apresentados os métodos para aquisição, processamento e classificação dos sinais, divididos em três ensaios, o primeiro realizado com sinais sinteticamente produzidos e os outros dois com dados reais. Cada uma dessas etapas será explicada em detalhes nas Seções 4.1, 4.2 e 4.3.

Como apresentado no capítulo 4, os dados foram analisados por uma RNA do tipo PMC. Essa rede foi a escolhida devido ao fato de apresentar as características necessárias para o desenvolvimento do projeto e, também, por ter apresentado resultados satisfatórios em trabalhos anteriores onde foram empregadas RNA para se fazer classificação de determinados tipos de sinais.

Foi utilizado um toolbox do MATLAB, devidamente desenvolvido para se realizar classificação de padrões, executado pela função `nprtool`. Esta ferramenta executa uma PMC com uma camada de entrada, uma camada intermediária e uma camada de saída.

Informações sobre número de entradas da RNA e quantidade de neurônios nas camadas intermediária e de saída são colocadas ao longo deste capítulo.

4.1 Ensaio 1 – Dados com sinais sinteticamente produzidos

No primeiro ensaio, foram utilizados dados sinteticamente produzidos, obtidos através de um simulador de amostras de sinais Profibus DP desenvolvido para esta finalidade. Detalhes sobre este simulador podem ser visualizado em TORRES (2011) e MOSSIN (2012). Estes dados têm como objetivo validar a rede neural e, a partir dos resultados obtidos nesta

etapa é possível saber se uma RNA é ou não eficiente para classificar sinais Profibus. A simulação dos sinais teve como base a observação de sinais Profibus adquiridos em instalações industriais com as características de interesse e em PROFIBUS INSTALLATION GUIDELINE FOR COMMISSIONING (2006). Inicialmente, foram simulados quatro classes de sinais hipoteticamente provenientes de redes com as seguintes características:

- Rede sem problemas de comunicação;
- Rede com problemas devido a cabeamento excessivamente longo;
- Rede com problemas devido a falta de terminadores habilitados;
- Rede com problemas devido a excesso de terminadores habilitados.

As figuras 4.2, 4.3, 4.4 e 4.6 apresentam exemplos dos sinais simulados utilizados.

Teoricamente, como descreve a norma, o sinal Profibus apresenta como característica uma onda quadrada, com amplitude variando de -3 V a 3 V (amplitude ideal do sinal Profibus é de 5Vpp, porém é aceitável sinais que medem até 7 Vpp) e baixo nível de ruído [CERTIFIED PROFIBUS ENGINEER COURSE, 2009]. A Figura 4. 1 apresenta um exemplo de sinal considerado ideal e, na Figura 4. 2 é possível observar um exemplo de sinal simulado em laboratório e o respectivo sinal coletado em uma rede real. A amplitude máxima de ruído é entre 0,5 Vpp, valor este considerado normal. Quando a amplitude do ruído ou o nível de tensão do sinal apresentam valores fora dessas faixas, há um comprometimento no sinal que está sendo transmitido e a rede já não consegue mais garantir a comunicação. Se um nível tensão acima de 7 Vpp for observada, um condutor de compensação entre os pontos de aterramento deve ser instalado [NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998].

Figura 4. 1 - Características Aceitáveis de um Sinal Profibus

FONTE: [CERTIFIED PROFIBUS ENGINEER COURSE, 2009].

i. Sinal colhido em laboratório:

ii. Sinal reproduzido pelo simulador:

Figura 4. 2 - Sinal Profibus DP sem Problema de Comunicação

Em um sinal com problema devido a cabo longo, pode-se observar que, devido ao efeito capacitivo na linha, ocorre um abaulamento do sinal, ou seja, este problema gera um sinal onde existe uma borda de subida lenta. Ver Figura 4. 3. Esse problema ocorre quando o comprimento da linha de dados não obedece aos limites impostos pela norma EN50170 [NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA], que vai de 1200m para redes com um *baudrate* de 9,6Kbps até 100m para redes com um *baudrate* de 12Mbps.

i. Sinal colhido em laboratório:

ii. Sinal reproduzido pelo simulador:

Figura 4. 3 - Sinal Profibus DP com Problema de Cabo Longo

Na Figura 4. 4 é apresentada a característica de um sinal com problema devido à falta de terminadores habilitados (o ideal são dois terminadores habilitados no barramento, um no início e outro no final da linha de dados) [NORMATIVE PARTS OF PROFIBUS FMS, DP AND PA, 1998]. Neste caso há um aumento da amplitude do sinal. A função do terminador é evitar que o sinal seja refletido quando ele chega ao fim do barramento. Se ao chegar no fim dessa linha o sinal não encontrar um terminador para ‘absorvê-lo’, este sinal voltará a percorrer a linha de dados, porém em sentido oposto e em determinado ponto encontrará com o sinal que está sendo transmitido. Ambos os sinais se somarão (sinal refletido ficará sobreposto ao sinal transmitido), fazendo com que um sinal com amplitude aumentada seja formado.

Figura 4. 4 - Sinal Profibus DP com Problema de Falta de Terminador

Por fim, na Figura 4.6 é apresentado o sinal correspondente ao excesso de terminadores do tipo não isoladores, habilitados. Neste caso há uma atenuação na amplitude do sinal transmitido. Este fato ocorre, pois, como os terminadores são conectados em paralelo na linha de dados, o cálculo da impedância é feito de acordo com a Equação 7. Note que, usando esta equação, quanto maior a quantidade de terminadores habilitados, menor será o valor da impedância na linha. A Figura 4. 5 mostra um circuito de ligação com impedâncias em paralelo. O gráfico do sinal Profibus é representado por Tempo vs. Tensão. Pela lei de Ohm, mostrada na Equação 8, pode-se observar que, para um valor constante de corrente no barramento, o valor da impedância é diretamente proporcional ao valor da tensão. Portanto, quanto menor o valor da impedância, menor será o valor da tensão. Isso explica o fato do sinal ser atenuado nessa situação.

$$\frac{1}{Z_{total}} = \frac{1}{Z_1} + \frac{1}{Z_2} + \frac{1}{Z_n} \quad (7)$$

Onde:

Z_{total} = valor da impedância total na linha;

Z_1, Z_2, Z_n = valor da impedância de cada terminador.

Figura 4. 5 - Exemplo de Circuito com Impedâncias em Paralelo

$$V_{rms} = Z * I_{rms} \quad (8)$$

Onde:

V_{rms} = valor da tensão na linha;

Z = valor da impedância na linha;

I_{rms} = valor da corrente na linha.

i. Sinal colhido em laboratório:

ii. Sinal reproduzido pelo simulador:

Figura 4. 6 - Sinal Profibus DP com Problema de Excesso de Terminador

Para cada um dos problemas apresentados, foi gerada no simulador 50 bits para cada classe de problema. Cada bit foi amostrado em 30 pontos e então armazenados em um arquivo com extensão “.dat” que foi usado como entrada da RNA. Para compreensão deste esquema de elaboração do conjunto de treinamento, ver Figura 4. 7.

Figura 4. 7 - Esquema da relação entre a quantidade de pontos/bit e a quantidade de bits representando uma situação da rede

Dessa maneira, com estes 4 sinais simulados, treinou-se uma rede neural artificial do tipo PMC contendo 30 entradas, 1 camada neural escondida e uma camada neural de saída, com 4 saídas. Na camada neural escondida foram realizados testes utilizando-se 10, 15, 20 e 30 neurônios. Após definir a arquitetura da rede, foi necessário escolher a melhor forma de treiná-la. Decidiu-se utilizar um método que se baseia no gradiente descendente. De acordo com BRAGA (2000), a utilização deste método exige que a função de ativação seja contínua, diferenciável e, de preferência, não-decrescente. A função de ativação é responsável por limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua imagem funcional (SILVA et. al., 2010). Para o caso das redes PMC, a função de ativação do tipo Sigmoidal é a mais utilizada. Utilizou-se para estes treinamentos, testes e validações o toolbox de Redes Neurais do Matlab (*Neural Network Toolbox*), inicializado através do comando *nprtool*. Essa ferramenta é responsável por processamento de sinais e foi modelada de acordo com a necessidade do sistema. Inicialmente, foi necessário carregar os dados de entrada da rede e os dados “alvo” (*targets*). Neste caso, os dados de entrada são as amostras do sinal simulado enquanto que os dados “alvo” são as classificações feitas pelos especialistas para cada uma das amostras, ou seja, para cada sinal amostrado, classificou-se o sinal como “funcionando normalmente”, “cabo longo”, “falta de terminadores habilitados”, e “excesso de terminadores habilitados”, o que faz com que o arquivo de entrada da RNA tenha 200 bits, ou seja, 50 para cada uma das situações apresentadas. Após os dados terem sido carregados na rede, iniciou-se o seu treinamento. Os resultados são apresentados na Tabela 4.

1.

Tabela 4. 1 - Dados de Treinamento da RNA

Nº de Neurônios	10	15	20	30
Nº de Épocas	94	74	112	464
Tempo (seg.)	8	10	25	186

De acordo com os resultados apresentados na Tabela 4. 1, pode-se observar que ao utilizar 10 neurônios a rede convergiu com 94 épocas em um tempo de 8 segundos. Utilizando 15 neurônios, a rede convergiu com um número de épocas menor, porém, em um pouco mais de tempo. Já para os outros dois valores, 20 e 30, a rede demorou a convergir.

Devido ao fato de estes testes terem sido realizados de forma offline, os valores referentes ao tempo podem ser considerados insignificantes. Porém, quando os testes passarem a ser realizados de forma online, os tempos deverão ser considerados e, considerando-se os resultados da Tabela 4. 1, os valores referentes às configurações com 20 e 30 neurônios seriam descartados.

Além desses parâmetros, foi analisada a porcentagem de acerto nos testes realizados para cada configuração, ou seja, foi feita uma validação da rede aplicando-se o conjunto de teste e validação (15% das amostras para cada) e a partir disso, obteve-se a taxa de acerto (%) entre os valores desejados e os valores fornecidos pela rede (após o processamento). A Tabela 4. 2 mostra o melhor resultado para cada tipo de configuração.

Tabela 4. 2 - Porcentagem de Acerto

Tipos de Dados	Quantidade de dados para cada situação	Erro Quadrático Médio (MSE) ¹	%E ²
Treinamento	140	1,58792e-7	0
Validação	30	1,66019e-7	0
Teste	30	1,55504e-7	0

¹O MSE é o erro apresentado em relação aos valores observados e os valores obtidos pela rede.

² %E é a fração de amostras que são classificadas erroneamente.

A rede neural alcançou uma porcentagem de acerto na classificação de 100% dos dados apresentados. Credita-se este sucesso de classificação da RNA ao fato de os sinais simulados terem suas características de forma muito bem definidas, não apresentando em sinais de classes distintas nenhuma semelhança significativa.

Esses quatro tipos de sinais foram os únicos a serem simulados, pois as características de outras situações da rede não são descritas na literatura especializada, por exemplo, rede

com interrupção nas linhas de dados, redes com inversão nas linhas de dados, rede com conector desconectado da estação escravo, rede com curto-circuito entre as linhas de dados. O comportamento de uma rede real e as formas de onda referentes a outros tipos de situações de uma rede Profibus foram observados quando se iniciaram os testes reais.

Diante do sucesso apresentado neste ensaio, ficou comprovado que RNAs são eficientes para classificação de sinais Profibus DP. Como observado, foi desnecessário o uso de pré-processamento dos sinais devido ao fato de os sinais simulados terem apresentado cada uma de suas características bem distintas de uma situação para outra, ou seja, cada uma das quatro representações teve sua forma de onda com as características bem definidas, o que levou a RNA a reconhecer adequadamente cada tipo de sinal. Com isso, deu-se início à próxima etapa, que foi a coleta de sinais reais para treinamento e validação da rede neural. Os resultados referentes a esses ensaios são apresentados nos itens 4.3 e 4.4.

4.2 Ensaio 2 – Dados reais

Após a conclusão da etapa de dados simulados e, diante do sucesso no treinamento da RNA, foi iniciada a etapa de coleta dos dados reais. Para uma visão geral do sistema, tem-se a Figura 4. 8, que mostra como o sinal Profibus foi coletado, pré-processado e por fim, utilizado na RNA.

Todo o procedimento experimental foi realizado com uma rede Profibus, montada no Centro de Competência Profibus do Brasil (CCP), composta pelos seguintes equipamentos:

- Um mestre Siemens modelo STEP 7 - CPU315-2 DP
- Um escravo Siemens – Profibus DP - ET 200S
- Um escravo Sense – DP-KDN-2E17
- Um escravo Sense – DP-KD-2EA

- Um osciloscópio Tektronix TDS 2014
- Cabo Profibus – fabricante Poliron
- Conectores DB9 – fabricante Procentec

Figura 4. 8 - Esquema da Rede Profibus DP Utilizada na Coleta dos Dados

Figura 4. 9 - Esquema Geral do Projeto

A captura dos sinais de forma amostrada é realizado com o osciloscópio, que captura e salva estas amostras na forma amostrada. Os dados coletados são coletados com uma resolução de $2,5 \mu\text{s}/\text{div}$ e são baseados nos seguintes problemas simulados na rede:

- A) Rede funcionando normalmente – utilizando cabos de 1 m e 200 m;
- B) Rede com cabo rompido – utilizando cabo de 200 m;

C) Rede com curto-circuito entre as linhas de dados A e B – utilizando cabo de 200 m;

D) Rede com inversão das linhas de dados A e B – utilizando cabo de 200 m;

E) Rede com cabo excessivamente longo – utilizando cabo de 400 m.

Os problemas A, B, C, D e E foram simulados utilizando comprimentos de cabo variados, ou seja, cabos com 1m, 200m e 400m. Esses comprimentos foram escolhidos respeitando-se o limite de cabo do *baudrate* adotado para os testes. Porém, para o caso das simulações feitas para cabo excessivamente longo (caso E), o comprimento de cabo utilizado foi acima do permitido pela norma para o respectivo *baudrate*. Neste caso, a rede foi configurada para trabalhar a 1,5 Mbps, ou seja, o comprimento de cabo utilizado para a simulação de cabo longo foi de 400 m, sendo que a norma recomenda que para esta velocidade o comprimento não ultrapasse 200 m e para os demais testes o comprimento utilizado foi de 200 m, que é o comprimento máximo recomendado pela norma para este *baudrate* e 1 m, comprimento mínimo aceitável para qualquer situação.

4.2.1 Coleta das amostras

Quando os sinais são obtidos a partir do osciloscópio, eles são salvos em uma planilha Excel. Estas amostras representam um sinal Profibus DP, com vários bits, em um determinado intervalo no tempo. Cada um desses bits contém um determinado número de pontos. Sendo assim, a primeira coisa a ser feita é determinar a quantidade de pontos que terá no bit e, a partir daí, separar cada um dos bits colhidos neste intervalo. É possível determinar a quantidades de pontos/bit sabendo-se qual é a resolução do osciloscópio no momento da coleta. Neste caso a resolução era de 2,5 μ s/div. Isto fez com que, para um *baudrate* de 1,5

Mbps, cada bit tivesse 67 pontos. O número de pontos/bit corresponde ao número de entrada da RNA.

Como uma rede Profibus trabalha sempre com uma velocidade pré-configurada pelo operador e não há variação dessa velocidade durante a transmissão dos dados, a RNA não será testada com problemas em outras velocidades (além do 1,5 Mbps, considerada a velocidade “default” de redes Profibus). Sendo assim, todos os dados são coletados com a mesma resolução e mesmo *baudrate* e, cada RNA será treinada com as amostras referentes à apenas uma velocidade selecionada.

As amostras colhidas foram devidamente separadas através de um software desenvolvido em MATLAB, nomeado de *Extrator de Bits*. Detalhes sobre o funcionamento deste software pode ser visto no Apêndice 1. Após a extração dos bits, o próprio software gera um arquivo equivalente ao conjunto de bits extraídos da amostra analisada. Conforme mencionado o número de pontos/bit (número de colunas do arquivo) corresponde ao número de entradas da RNA.

Para conseguir detectar o número de pontos/bit nas amostras utilizou-se a equação 9:

$$N_{bit} = \frac{1}{T_{ponto} * Baud} \quad (9)$$

Onde:

N_{bit} = Número de pontos por bit;

T_{ponto} = Tempo para transmitir um ponto;

$Baud$ = Velocidade de transmissão da rede.

A Figura 4. 10 mostra como foi feito o cálculo da quantidade de pontos/bit.

Figura 4. 10 - Esquema do Cálculo do Número de Pontos/Bit

Após a conclusão desta tarefa, é necessário realizar um pré-processamento manual desses dados retirando-se das amostras os bits que não correspondiam exatamente à situação em questão.

4.2.2 Análise dos sinais reais

Conforme mencionado anteriormente, para a coleta de dados reais foram utilizados variados comprimentos de cabos para cada velocidade. Esses comprimentos foram considerados devido ao fato de o sinal tender a se degradar com o aumento da distância entre as estações ativa e passiva da rede, mesmo quando o *baudrate* escolhido é baixo. Essa situação pode ser observada na Figura 4. 11, que mostra dois exemplos de rede funcionando normalmente, com *baudrate* de 1,5 Mbps, porém com comprimentos de cabos diferentes.

Figura 4. 11 - Exemplo de uma Rede Funcionando Normalmente

Nota-se que para o sinal que representa uma rede funcionando normalmente, as características são as mesmas apresentadas no item 4.2, quando foi apresentado o gráfico de uma rede com funcionamento normal, com exceção dos picos de ruídos que ocorreram no início de algumas transições, o que é normal em redes reais, já que um ambiente real conta com alguns tipos de interferências.

Para o caso de curto-circuito entre as linhas de dados, a comunicação é interrompida nos equipamentos que estão próximos ao curto. Como pode ser observado na Figura 4. 12, o sinal é bastante ruidoso, o que torna difícil sua identificação entre as estações.

Figura 4. 12 - Exemplo de uma Rede com Problema devido a Curto-Circuito

Já no caso do sinal que representa um problema causado por cabo rompido, o sinal se comporta como no caso do problema com falta de terminadores habilitados, ou seja, há um aumento na amplitude do sinal. Isso ocorre pois, a rede no lado que houve a retirada do conector entende que realmente uma terminação foi perdida. Porém, a estação ativa não entende inicialmente, que uma estação passiva saiu da rede e continua tentando uma comunicação. Essa comunicação é perdida após alguns *retries* (valor configurado pelo operador da rede que informa quantas tentativas de comunicação deverão ser feitas do mestre para o escravo até que seja interrompida a comunicação, caso não haja uma resposta do escravo). Porém, neste caso, como o *retry* não foi configurado, a estação ativa continuou tentando uma comunicação. Um exemplo deste sinal pode ser visualizado na Figura 4. 13. Caso a desconexão do conector fosse na estação ativa, a rede perderia a comunicação e o único sinal que teria no cabo seria referente à tensão que estaria alimentando os terminadores.

Figura 4. 13 - Exemplo de uma Rede com Problema devido a Cabo Rompido

Para o problema relacionado a cabo longo, as características são as mesmas apresentadas no item 4.2. A Figura 4. 14 mostra um sinal real referente a este problema.

Figura 4. 14 - Exemplo de uma Rede com Problema devido a Cabo Longo

Para a situação que envolve uma inversão nas linhas de dados, pode-se observar que o sinal fica extremamente deformado, de forma que a rede não consegue garantir comunicação e, assim como explicado no problema com conector desconectado, haverá tentativas de comunicação do mestre com o escravo e após um determinado número de *retries* o mestre aborta a comunicação. Um exemplo deste sinal é mostrado na Figura 4. 15.

Figura 4. 15 - Exemplo de uma Rede com Problema devido a Inversão entre as Linhas de Dados A e B

Mais exemplos de formas de ondas para todas as situações simuladas na rede Profibus podem ser visualizados no Apêndice 2.

Após a conclusão da aquisição dos sinais digitais, deu-se início à etapa de treinamento e validação da RNA. Esta etapa é apresentada no próximo passo.

4.2.3 Treinamento e validação da RNA

Baseado nas amostras colhidas foi criado, manualmente, o arquivo de saída referente a cada entrada. Como dito anteriormente, a rede PMC possui aprendizado supervisionado, ou seja, o arquivo de saída é baseado no arquivo de entrada. Ele é elaborado ajustando-se os neurônios de acordo com os dados de entrada. Em seguida, iniciou-se os testes utilizando-se o *toolbox* do MATLAB, conforme descrito na Seção 4.2.

Assim como no ensaio com sinais simulados, foram realizados testes com 10, 15, 20 e 30 neurônios. A mesma rede neural do primeiro experimento foi re-treinada com um conjunto de 50 bits de cada classe de sinal real. A RNA foi re-treinada por 10 vezes e obteve margem muito baixa de acerto, em alguns casos chegando a apenas 44,2%.

Abaixo, na Tabela 4. 3, são apresentados os resultados desse ensaio. Nesta tabela podem-se observar as simulações que foram realizadas para o *baudrate*, de 1,5 Mbps bem como, o número de neurônios envolvidos nos testes, o comportamento da RNA (número de

épocas e tempo de treinamento) de acordo com a quantidade de neurônios configurados e por fim, a porcentagem de acerto para cada configuração.

Tabela 4. 3 - Resultados do Ensaio com Dados Reais

<i>Baudrate</i>	Situações Testadas em Laboratório	Nº de Neurônios	Nº de Épocas	Tempo de Treinamento	Porcentagem de Acerto no Treinamento
1,5 Mbps	Cabo Curto (1m) • Teste base;	10	89	7,6 s	44,8%
	Cabo Limite (200m) • Teste base; • Curto-circuito;	15	122	11 s	45%
	• Interrupção em uma das linhas de dados;	20	154	14 s	44,4%
	• Inversão das linhas de dados; • Rede com conector desconectado. Cabo Longo (400m)	30	134	13,2 s	44,2%

Esta baixa margem de acerto se deve às semelhanças existentes entre os sinais colhidos. Tal semelhança entre amostras de sinais de classes diferentes resulta na imprecisão da rede neural em classificar corretamente cada sinal em sua respectiva classe. Nota-se então que estes sinais “indesejados” podem ser eliminados e apenas os bits que realmente caracterizam um determinado problema devem ser mantidos entre as amostras de entrada da RNA. Assim, realiza-se um pré-processamento do sinal, descrito no item 1) da Seção 4.4 e um terceiro ensaio foi realizado. Os resultados dessa etapa são apresentados na Seção 4.4.

Como pode-se observar, não foram considerados os ensaios realizados com excesso e falta de terminadores habilitados, pois essas simulações em laboratório não apresentaram uma deformação significativa do sinal, ou seja, a rede se comportou como se não tivesse nenhum problema.

Na Tabela 4. 3, a diferença de valores entre o número de épocas, o tempo de convergência da rede e a porcentagem de erro para cada número de neurônios, não foi muito significativa. Portanto, a próxima etapa, emprega RNAs com 20 neurônios.

Na próxima seção são apresentados os resultados do terceiro ensaio, onde os dados são pré-processados manualmente e a uma RNA para cada problema é re-treinada com novas entradas.

4.3 Ensaio 3 – Dados reais pré-processados

Para se obter um grau satisfatório de classificação, pode-se tratar o sinal de entrada, organizando-o de forma que a RNA consiga melhor captar as informações dentro dos dados que estão sendo apresentados. A solução de problemas complexos exige uma grande quantidade de conhecimento e também a manipulação desse conhecimento, com o objetivo de criar soluções para eles (GONSCHOROWSKI, 2007). Após o treinamento da RNA, esta é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções que eram até então desconhecidas (SILVA, 2010).

Experimentou-se, após a aquisição do sinal uma análise e seleção dos pontos, onde os bits que não estavam dentro do padrão de cada problema, foram eliminados manualmente da amostra. Esta etapa é importante devido ao fato de se ter, no conjunto de treinamento, bits que não apresentam as características reais do problema em questão ou que são semelhantes a outros problemas. Um exemplo deste fato pode ser observado na Figura 4.16 **Erro! A origem da referência não foi encontrada..** Pode-se notar que alguns bits apresentam sua forma diferente dos demais bits de sua classe, o que faz com que eles não tenham a característica dos demais bits do conjunto de treinamento. Em todos os conjuntos de amostras referentes aos problemas de instalação da rede no conjunto de treinamento existem esses tipos de bit e, portanto, a seleção manual tem o objetivo de deixar as amostras referentes a cada problema da

forma mais uniforme possível. Isso assegura que a RNA não seja treinada para classificar erroneamente os bits que não estiverem de acordo com o padrão desejado. Após a seleção manual, o conjunto de treinamento da Figura 4.16, fica reduzido, como mostrado na Figura 4.17.

Figura 4. 16 - Exemplo de um conjunto de treinamento contendo bits fora do padrão da classe apresentada

Figura 4. 17 - Exemplo de um conjunto de treinamento contendo apenas os bits referentes à classe apresentada

Após a conclusão desta etapa os dados passam a serem processados pela RNA.

4.3.1 Organização das RNAs

Após a realização de eliminação manual dos dados indesejados em cada conjunto de amostras, formaram-se os conjuntos de treinamento. Neste terceiro experimento utilizou-se uma RNA para cada uma das situações analisadas na rede Profibus, ou seja, cada RNA foi treinada para reconhecer somente um determinado tipo de problema e no momento da classificação, o mesmo conjunto de treinamento era enviado para todas as RNAs do software, e o resultado de saída de cada RNA é zero ou um.

Como descrito anteriormente as situações analisadas foram: rede sem problemas de comunicação utilizando-se cabos de 1m e 200 m, rede com problema de inversão das linhas da dados A e B utilizando-se cabo de 200 m, rede com problema de curto-circuito entre as linhas de dados a e B utilizando-se cabos de 200 m, rede com problema de cabo rompido utilizando-se cabo de 200 m e rede com problema de cabo longo utilizando-se cabo de 400 m. Para cada uma destas situações foram selecionados manualmente os 20 bits que melhor caracterizam essas situações e, por fim, foi montado um conjunto de treinamento contendo 100 bits.

Assim como nos experimentos anteriores foi realizado com 67 pontos/bit e, adicionalmente, também é repetido com amostras de 22 pontos/bit. Para se chegar neste número, são retirados do primeiro conjunto de treinamento (contendo 67 pontos/bit) dois de cada três pontos do bit. Os resultados apresentados são baseados nesses dois conjuntos de treinamento.

Como é utilizada uma rede neural para reconhecer cada situação da rede Profibus, esse conjunto de entrada tem seu conjunto de saída correspondente baseado no problema que cada rede neural é treinada para reconhecer.

A rede neural treinada para reconhecer a situação de rede sem problema de comunicação utilizando-se cabo de 1 m, por exemplo, tem o conjunto de treinamento de saída

montado de forma que os neurônios referentes a esta situação são especificados como (1,0) e os demais neurônios, que se referiam aos demais problemas são especificados como (0,1). O mesmo é feito para todos os problemas, ou seja, para cada situação que foi isolada, os neurônios referentes a ela são especificados como (1,0) e os demais são especificados como (0,1). Então, a rede neural tem, para cada caso, uma saída binária, onde a resposta é “a situação da rede Profibus é ...” ou “a situação da rede Profibus não é ...”. No caso de não ser a situação principal, significa que a situação da rede é qualquer uma das outras cinco situações que são especificadas como (0,1). Como existem seis redes neurais, ou seja, uma para cada situação, o mesmo conjunto de treinamento é “carregado” para as seis redes neurais e uma delas conseguirá identificar o problema, conforme esquema na Figura 4. 18.

Figura 4. 18 - Esquema de classificação dos dados utilizando-se uma RNA para cada situação da rede

4.3.2 Resultados

Os resultados dessa etapa foram plenamente satisfatórios. Usando-se uma rede neural para o reconhecimento de cada situação da rede Profibus, conseguiu-se classificar corretamente 100% dos sinais que foram apresentados tanto para os testes com 22 pontos/bit quanto para os testes com 67 pontos/bit. Consequentemente, o MSE obteve um valor bem próximo de zero, enquanto o %E foi de 0%, ou seja, nenhum erro foi apresentado no reconhecimento. As Tabelas 4.4 e 4.5 mostram os resultados para o treinamento de cada uma das RNAs, tanto para os testes com 22 pontos/bit quanto para os testes com 67 pontos/bit.

Tabela 4. 4 - Porcentagem de Acerto para RNA com 22 pontos/bit

Tipos de Dados	Quantidade de dados para cada situação	MSE	%E
Rede OK com cabo de 1 m			
Treinamento	70	1,19950e-2	0
Validação	15	1,06646e-3	0
Teste	15	1,63841e-3	0
Rede OK com cabo de 200 m			
Treinamento	70	1,89339e-7	0
Validação	15	1,87597e-7	0
Teste	15	7,21138e-7	0
Rede com cabo rompido			
Treinamento	70	1,90264e-7	0
Validação	15	1,90774e-7	0
Teste	15	9,07652e-8	0
Rede com curto-circuito entre as linhas de dados			
Treinamento	70	9,67401e-8	0
Validação	15	2,39832e-8	0
Teste	15	4,66096e-8	0
Rede com inversão nas linhas de dados			
Treinamento	70	8,07556e-8	0
Validação	15	4,79967e-8	0
Teste	15	3,17229e-8	0
Rede com cabo longo			
Treinamento	70	2,83399e-2	0
Validação	15	4,09082e-3	0
Teste	15	2,2789e-2	0

Tabela 4. 5 - Porcentagem de Acerto para RNA com 67 pontos/bit

Tipos de Dados	Quantidade de dados para cada situação	MSE	%E
Rede OK com cabo de 1 m			
Treinamento	70	1,19449e-2	0
Validação	15	1,61428e-3	0
Teste	15	3,64503e-4	0
Rede OK com cabo de 200 m			
Treinamento	70	1,75193e-1	0
Validação	15	9,95242e-2	0
Teste	15	1,82840e-1	0
Rede com cabo rompido			
Treinamento	70	2,33350e-7	0
Validação	15	1,60926e-7	0
Teste	15	1,26406e-7	0
Rede com curto-circuito entre as linhas de dados			
Treinamento	70	8,60291e-8	0
Validação	15	2,64242e-8	0
Teste	15	1,85804e-5	0
Rede com inversão nas linhas de dados			
Treinamento	70	9,16566e-8	0
Validação	15	8,55615e-8	0
Teste	15	4,72608e-8	0
Rede com cabo longo			
Treinamento	70	6,49351e-2	0
Validação	15	5,88252e-2	0
Teste	15	5,88236e-2	0

Com relação ao número de épocas e o tempo de treinamento gastos nesta etapa, os resultados são apresentados nas Tabelas 4.6 e 4.7.

Tabela 4.6 - Dados de Treinamento das RNAs com 22 entradas

	Nº de neurônios	Nº de épocas	Tempo (s)
Rede OK – cabo 1 m	20	44	0,6
Rede OK – cabo 200 m	20	53	0,8
Cabo rompido	20	46	0,8
Curto-circuito entre as linhas de dados	20	74	1,2
Inversão entre as linhas de dados	20	28	0,1
Cabo longo	20	67	1,2

Tabela 4.7 - Dados de Treinamento das RNAs com 67 entradas

	Nº de neurônios	Nº de épocas	Tempo (s)
Rede OK – cabo 1 m	20	65	1,3
Rede OK – cabo 200 m	20	127	2,7
Cabo rompido	20	42	0,9
Curto-circuito entre as linhas de dados	20	44	1
Inversão entre as linhas de dados	20	65	1,4
Cabo longo	20	73	1,2

4.4 Conclusão

Os testes realizados na etapa 4.3 mostram que o melhor caminho para o reconhecimento deste tipo de sinal é a seleção manual dos bits combinado com a divisão das redes neurais, treinando-as para reconhecer cada situação da rede e, prova que uma rede neural do tipo PMC é eficiente no reconhecimento de sinais Profibus.

5 Conclusões

O Profibus é um padrão aberto de rede de campo, independe de fornecedores. Este padrão é constituído de tecnologia já amadurecida, mas que mesmo assim vem evoluindo continuamente, adequando-se às novas demandas do mercado. Nesta evolução contínua, incluem-se também as ferramentas de diagnóstico, que facilitam cada vez mais o trabalho dos usuários.

Este trabalho propôs procedimentos baseado em Inteligência Artificial para se diagnosticar problemas de instalação relacionados à camada Física da rede Profibus DP.

A primeira conclusão e a mais importante é que é possível utilizar RNA para o diagnóstico dos problemas de instalação que causam distúrbios na forma de onda dos sinais transmitidos na camada Física do protocolo Profibus DP.

Além dessa conclusão, é notável que para utilizar Redes Neurais, o desenvolvedor precisa selecionar o melhor tipo de rede para se resolver o problema que se deseja tratar, deve-se também escolher a melhor arquitetura desta rede e os métodos de pré-processamento adequados para o caso. Para esta pesquisa a PMC foi testada e aprovada. O critério de seleção entre diferentes redes é pragmático, ou seja, é escolhida aquela que atinge os objetivos esperados. Também não está assegurada sempre a reprodutibilidade dos resultados, já que a cada treinamento os pesos iniciais são aleatórios, o que pode conduzir a diferentes áreas da superfície de erro.

Os dados para testes reais foram colhidos em laboratório. Cada situação da rede foi simulada no laboratório e as respectivas formas de ondas foram coletas com o auxílio de um osciloscópio. Inicialmente, as formas de ondas coletadas apresentaram muitas semelhanças

entre si, o que levou a RNA a apresentar uma porcentagem de acerto muito baixa. Este fato também ocorreu, pois estava sendo usada apenas uma RNA para se classificar todos os tipos de dados. Porém, quando foi testada a possibilidade de se utilizar uma RNA para cada situação da rede Profibus, esta apresentou resultados satisfatórios, classificando corretamente 100% dos dados apresentados. Com este resultado, decidiu-se utilizar este tipo de configuração no trabalho de MOSSIN (2012), que é um projeto maior, que consiste no desenvolvimento de uma ferramenta de diagnóstico de redes Profibus DP baseado em Sistemas Inteligentes. Este resultado, bem como os resultados iniciais do trabalho, foram publicados em SOUZA (et. al. 2011), SOUZA (et. al. 2012) e MOSSIN (et. al. 2011).

Também é importante destacar que os dados coletados em laboratórios são muito diferentes dos dados coletados em ambientes de indústria onde o barramento Profibus está sujeito a vários tipos de ruídos e interferência eletromagnética. Com isso, foi necessário um critério maior na coleta dos dados em laboratório, para que se conseguisse sinais fieis às características de cada tipo de situação.

Referências Bibliográficas

ALASMAR, M.; ANGELOTTI, L.R.; GARCIA, L.M. (2008). Redes Industriais, Profibus/DP – CCM, Profibus/PA – Instrumentação. III Fórum Internacional de Automação do Setor Sucroalcooleiro e Alimentício. 2008.

AMINIAN, M., AMINIAN, F. (2000). Neural Network Based Analog-Circuit Fault Diagnosis Using Wavelet Transform as Preprocessor. IEEE Transactions on Circuits and Systems – II Analog and Digital Signal Processing, Vol. 47, Nº. 2, p. 151-156, February, 2000.

ANGRISANI, L., DAPONTE, P., D'APUZZO, M. (2001). Wavelet Network-Based Detection and Classification of Transients. IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, Vol. 50, Nº. 5, p. 1425-1435, October, 2001.

AWADALLAD, M. A., MORCOS, M. M. (2003). Application of AI Tools in Fault Diagnosis of Electrical Machines and Drives – An Overview. IEEE Transactions on Energy Conversion, Vol. 18, Nº 2, p. 245-251, June 2003.

BECRAFT, W. R. (1993). Diagnostic Applications of Artificial Neural Networks. Proceedings of 1993 International Joint Conference on Neural Network. Pages 2807 to 2810.

BERGE, J. (2002). Fieldbuses for Process Control: Engineering, Operation and Maintenance. ISA – The Instrumentation, Systems and Automation Society, 2002.

BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. L. F. (2000). Redes Neurais Artificiais – Teoria e Aplicações. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A, 2000.

BRANDÃO, D. (2000). Bloco Funcional para controle Fieldbus por variáveis de estado. São Carlos. 117p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000.

CASSIOLATO, C.; TORRES, L. H. B.; CAMARGO, P. R. (2009). Profibus – Descrição Técnica. São Paulo: Associação Profibus Brasil, 2011.

Certified Profibus Enginer Course, 2009. Delivered by the Automation Systems Centre Manchester Metropolitan University. Manchester Metropolitan University. 2009.

Consoft NetTEST II. Disponível em
http://www.comsoft.de/html/icpe/Profibus/analysis/nettest.htm?_kk=Profibus%20test&_kt=f2dcd705-c5a6-4654-9400-5481b6104d46&gclid=CNri68KlraUCFQta7AodzBneaA.
Acesso em: 26 nov. 2010.

CYBENKO, G. (1989). Approximation by Superpositions of a Sigmoid Function. Mathematics of Control, Signal and Systems, 2:303-314, 1989.

D'EMERY, R. A. (2007). Aplicação de Análises Estatística e Neural para Reconhecimento de Sinais de Odores. 192p. Dissertação (Mestrado) – Departamento de Estatística e Informática da Universidade Federal Rural de Pernambuco, 2007.

DEMUTH, H., BEALE, M., HAGAN, M. (2002). Neural Network Toolbox™ 6 – User's Guide. The MathWorks™, 2002.

DINIZ, P. S. R.; SILVA, E. A. B.; NETTO, S. L. (2004). Processamento Digital de Sinais – Projeto e Análise de Sistemas. Rio de Janeiro: Bookman, 2004.

FERNANDES, R. A. S. (2009). Identificação de Fontes de Correntes Harmônicas por Redes Neurais Artificiais. São Carlos. 127p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2009.

FERREIRA, D. D., MARQUES C. A. G., CERQUEIRA, A. S., DUQUE, C. A., RIBEIRO, M. V. (2007). Sistema Automático para Detecção e Classificação de Distúrbios Elétricos em Qualidade da Energia Elétrica, p. 53-62. Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007. Universidade Federal de Juiz de Fora, Minas Gerais, 2007.

GERAL Profibus PA - MANUAL DE INSTRUÇÃO, OPERAÇÃO E MANUTENÇÃO – Smar Equipamentos Industriais Ltda (2009).

GONSCHOROWSKI, J. S. (2007). Processamento de Sinais e Reconhecimento de Padrões de Resposta de Sensores de Gases através da Geometria Fractal. 114p. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2007.

GÜLER, I., ÜBEYLI, E. D. (2005). An Expert System for Detection of Electrocardiographic Changes in Patients with Partial Epilepsy using Wavelet-based Neural Networks. Department of Electronic and Computer Education, Faculty of Technical Education, Gazy University and Department of Electrical and Electronic Engineering, Faculty of Engineering. Ankara, Turkey, p. 62-71, 2005 IEEE.

HERNÁNDEZ, D. (2008). Using Complex Neural Networks on Noise Cancelling. Facultad de Ingeniería Mecánica, Eléctrica y Electrónica. Universidad de Guanajuato. Comunidad de Palo Blanco, México. IEEE, p. 138-142, (2008 Seventh Mexican International Conference on Artificial Intelligence).

HUANG, Y. C., HUANG, C. M., SUN, H. C., LIAO, Y.S. (2010). Fault Diagnosis Using Hybrid Artificial Intelligent Methods. 5th IEEE Conference on Industrial Electronics and Applications, p. 41-44, 2010.

HÜSEMANN, R., PEREIRA, C. E. (2007). A multi-protocol real-time monitoring and validation system for distributed fieldbus-based automation applications, Control Engineering Practice, Volume 15, Issue 8, August 2007, Pp. 955-968, 2007.

International Standard CEI/IEC 60529 Edition 2.1. 2001-02. Degrees of protection provided by enclosures (IP code). Reference Number CEI/IEC 60529:1989+A1:1999.

- JAIN, M. B., JAIN, A., SRINIVAS, M. B. (2008). A Web based Expert Systems Shell for Fault Diagnosis and Control of Power System Equipment. International Conference on Condition Monitoring and Diagnosis, Beijing, China, April 21-24, 2008.
- KAMEL, T. S., HASSAN, M. A. M., EL-MORSHEDEY, A. (2009). Using a Combined Artificial Intelligent Approach In Distance Relay for Transmission Line Protection in EPS. Elec. Power and Machines Department, Faculty of Engineering, Cairo University, Egypt. 2009 IEEE
- KHANH, T. D., PISA P., SMOLIK, P. (2009). An Open Implementation of Profibus DP. Czech Technical University in Prague, Faculty of Electrical Engineering Department of Control Engineering, 2010.
- KINDERMANN, G., CAMPAGNOLO, J. M. (1995). Aterramento Elétrico. 4ª Edição. Sagra-DC Luzzatto, 1998.
- LALLO, P. R. U. (1999). Signal Classification by Discrete Fourier Transform. Signals School, Finland. IEEE. P. 197-201. 1999.
- LAMAR, M. V.; Bhuiyan, M. S.; Iwata, A. (2003). Reconhecimento de Posturas Manuais Usando Redes Neurais. VI Congresso Brasileiro de Redes Neurais, p. 307-312, 2-5 de Junho de 2003, Centro Universitário da FEI, São Paulo – SP – Brasil.
- LIRA, M. M. S. (2004). Wavelets na Compactação e Processamento de Sinais de Distúrbio em Sistemas de Potência para Classificação via Redes Neurais Artificiais. Recife. 132 p. Tese (Doutorado) – Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-graduação em Engenharia Elétrica, Pernambuco, 2004.
- LUZARDO, E.; PAREDES, J. L.; RAMIREZ, J. (2007). A Kernel Based Approach for Classification of Eletromagnetic Interference Signals. Revista Tecnica Ing. Univ. Zulia. Vol. 30, n. 1, p. 33-45. 2007.
- MAKI, Y., LOPARO, K. A. (1997). A Neural Network Approach to Fault Detection and Diagnosis in Industrial Processes. IEEE Transactions on Control Systems Technology, Vol. 5, nº 6, p. 529-541, November, 1997.
- MIRANDA, S. G. (2003). Princípios de Transformada de Fourier e suas Aplicações em Telecomunicações. Revista UNORP, v. 4 (2), p. 55-71, Julho de 2003.
- MITCHELL, R. W. Profibus – A Pocket Guide. Research Triangle Park: ISA – The Instrumentation, Systems and Automation Society, 2004.
- MOSSIN, E. A., SOUZA, R. C., TORRES, R. V., SILVA, F. A., BRANDAO, D. (2011). Diagnóstico Inteligentes de Redes Profibus DP. Revista Controle & Instrumentação. Nº 172. 2011.
- MOUTINHO, A. M.; THOMÉ, A. C.; COELHO, P. H.; NETO, L. B.; MEZA, L. A. (2003). Localizador de Padrões Faciais: Uma Aplicação Usando-se Redes Neurais Artificiais. Engevista, v. 5, n. 10, p. 19-30, dezembro de 2003.

NAIDU, S. R., ZAFIRIOU, E., McAVOY, T. J. (1990). Use of Neural Networks for Sensor Failure Detection in a Control System. American Control Conference. Pittsburgh, Pennsylvania, p. 49-55, June 21-22, 1989. IEEE

NARENDRA, K. S., PARTHASARATHY K. (1990). Identification and Control of Dynamical Systems Using Neural Networks. IEEE Transactions on Neural Networks. Vol. 1. Nº 1, p. 4-27, March, 1990.

NBR-5410 – Instalações Elétricas de Baixa Tensão (1997). Associação Brasileira de Normas Técnicas.

NETO, C. D. (2008). O Profissional de Automação com Nível Superior. III Fórum Internacional de Automação do Setor Sucroalcooleiro e Alimentício. 2008.

Normative Parts of Profibus FMS, DP and PA, according to the European Standard EN5170 Volume 2. Edition 1.0 (1998).

NUNES, L. C. (2007). Métodos Quimiométricos Aplicados na Determinação Espectrofotométrica de Misturas de Aminoácidos. 128p. Dissertação (Mestrado) – Universidade Federal de Viçosa, 2007.

ORHAN, U., HEKIM, M., ÖZER, M. (2010). Discretization Approach to EEG Signal Classification Using Multilayer Perceptron Neural Network Model. IEEE, p.

PARISI, R., CLAUDIO, E. D., LUCARELLI, G., ORLANDI G. (1998). Car Plate Recognition by Neural Networks and Image Processing. INFO-COM Dpt. University of Rome “La Sapienza”. Rome, Italy, p. 195-198, 1998 IEEE

PERELMUTER, G., CARRERA, E.V., VELLASCO, M., PACHECO M.A., (1995). Reconhecimento de Imagens Bidimensionais Utilizando Redes Neurais Artificiais. Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, p. 197-204, 1995.

PINELLI, R. (2006) Curso de Integradores. Rev. 0. Associação Profibus. Brasil.

Profibus Installation Guideline for Cabling and Assembly. Version 1.0.6. May 2006.

Profibus Installation Guideline for Commissioning. Version 1.0.2. November 2006.

Profibus Interconnection Technology Guideline. Version 1.4. January 2007. Order Nº. 2.142.

ProfiTrace User Manual. Disponível em: www.procentec2.com/profitrace/downloads/ProfiTrace2-Manual-CZ.pdf. Acesso em: 02 jun. 2009.

RIBEIRO, F. A. L. (2001). Aplicação de Métodos de análise Multivariada no Estudo de Hidrocarbonetos Policíclicos Aromáticos. 174p. Dissertação (Mestrado) – Unicamp, Campinas, 2001.

SHAMSUDDIN, N., MUSTAFA, M. N., HUSIN, S., TAIB, M. N. (2005). Classification of Heart Sounds Using a Multilayer Feed-forward Neural Network. Electronics and Information Technology Centre. Selangor, Malaysia, p. 87-90, 2005. IEEE

SHEPHERD, G.M.; KOCH. C. The synaptic organization of the brain. Oxford University Press, New York, 1990.

SHOSHANI, G., MITSCHKE, S., STEPHAN, S. (2010). Industrial Fieldbus Technology and Fieldbus Cable Overview – Cable Standards and Electrical Qualifications. Copyright Material IEEE. Paper No. PCIC-2010-36.

SILVA, I. N., OLIANI, R. S. (2005). Redes Neurais Artificiais. 2005. Escola de Engenharia de São Carlos, USP, São Carlos.

SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A. (2010). Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. 2010. ArtLiber Editora. 2010.

SILVA, W. (2008). Métodos para Diagnóstico de Falhas e Avaliação de Desempenho em Redes Profibus DP. 2008. Monografia (Especialização em Automação Industrial) – Escola de Engenharia, UFMG, Belo Horizonte.

SOUZA, R. C., MOSSIN, E. A., BRANDAO, D. (2011). Ferramenta de Diagnóstico para Redes Profibus DP baseado em Redes Neurais Artificiais. 15º Congresso Internacional e Exposição de Automação, sistemas e Instrumentação. ISA 2011.

SOUZA, R. C., MOSSIN, E. A., BRANDAO, D. (2012). Physical Diagnostic for Profibus DP Networks Base don Artificial Neural Network. IEEE International Conference on Industrial Technology (ICIT). 2012.

SMAR Manual dos Procedimentos de Instalação, Operação e Manutenção – Profibus PA (2009). Disponível em: <http://www.smar.com/brasil2/Profibus.asp> . Acesso em: 31 jan.. 20011.

Softing Profibus Tester Disponível em: <http://softing-Profibus-tester.software.informer.com>. Acesso em: 02 jun. 2009.

Softing BC-502-PB. Disponível em <http://www.softing.com/home/en/industrial-automation/products/network-diagnostics/Profibus/Profibus-inspector.php>. Acesso em: 26 nov. 2010.

STALLINGS, W. (1997). Data and Computer Communications. Prentice Hall, 1997.

STEMMER, M. R. (2001). Sistemas Distribuídos e Redes de Computadores para Controle e Automação Industrial. 2001. Santa Catarina: Universidade Federal de Santa Catarina.

TANEMBAUM, A. S., STEEN, M. V. (2002). Distributed Systems – Principles and Paradigms. Prentice Hall, 2002.

THOMESSE, J. P. (2005). Fieldbus technology in Industrial Automation. Manuscript received April 13, 2004; revised February 14, 2005. Proceedings of the IEEE, Vol. 93, No. 6, June 2005.

TORRES, L. H. B., (2008). Foundation Fieldbus. III Fórum Internacional de Automação do Setor Sucroalcoleiro e Alimentício. 2008.

Trebing+Himstedt xEPI 2 Disponível em <http://www.t-h.de/index.php?id=50&L=4>. Acesso em: 26 nov. 2010.

VENTURINI, V. P. (2007). Desenvolvimento de um Mestre Profibus com a Finalidade de Análise de Desempenho. 2007. Dissertação de Mestrado em Engenharia Mecânica – Escola de Engenharia de São Carlos, USP, São Carlos.

Technical Guideline Installation Guideline for Profibus-DP/FMS Version 1.0 September 1998.

Test Specifications for Profibus DP Slaves Version 2.3 March 2004.

User Manual Profibus Tester PB-T3. Version 1.70. 2008.

User Manual ProfiTrace 2.5.1 – Profibus Combi-Analyzer on USB, 2011.

WU, S., CHOW, W. S. (2004). Induction Machine Fault Detection Using SOM-Based RBF Neural Networks. IEEE Transactions on Industrial Electronics, Vol. 51, N° 1, p. 183-194, February 2004.

WU, Z. Y. B., ZARGARI, N. (2000). Online Mechanical Fault Diagnosis of Induction Motor by Wavelet Artificial Neural Network Using Stator Current. IEEE, p. 1183-1188. 2000.

APÊNDICE A

Algoritmo do Software Extrator de Bits

Os dados colhidos de forma amostrada através do osciloscópio são exportados para um arquivo em Excel. Esses dados são apresentados em forma de vetores, em duas colunas, que representam Tensão (V) vs. Tempo (s).

Inicialmente, o software ‘Extrator de Bits’ calcula o tempo gasto para transmitir 2 pontos simultâneos, ou seja, o tempo entre duas linhas. Em seguida, faz-se o inverso deste valor. Este resultado é multiplicado pela taxa de transmissão adotada pela rede e, novamente, após obter este resultado, faz-se o inverso deste valor. Este resultado corresponde ao número de pontos contidos em 1 bit.

Com este valor calculado, o software começa a analisar o sinal amostrado. A coleta das amostras/bit começa a partir da primeira transição no sinal. Neste ponto, os bits serão separados, e no final da separação o próprio software gera um arquivo com a extensão ‘.dat’ que é a extensão utilizada pelo toolbox da RNA PMC do Matlab.

Inicialmente, foi considerado apenas o uso da rede PMC, por isso este programa foi desenvolvido para atender às necessidades desta arquitetura.

O algoritmo desenvolvido segue abaixo.

```

NUMERIC = xlsread('1,5 - 1.xls');

Fs = 1 /(NUMERIC(2,3) - NUMERIC(1,3));
Baud = 1500000; %Esse valor deve ser mudado de acordo com a tava de transmissão que está sendo tratada

Nbit = floor(Fs/Baud);
N = size(NUMERIC(:,1));
Volt = NUMERIC(:,2);

%Procura a primeira transicao
for k=2:N(1),
    if ((Volt(k) > 0 && Volt(1) < 0)|| (Volt(k) < 0 && Volt(1) > 0) )
        break;
    end;
end;
Ind = k;

Nt = N(1)-k;
i=1;
Bit2 = zeros(2000,Nbit-2);

while 1,

    a = Ind+1;
    b = Ind+Nbit-2;
    Bit2(i,:) = Volt(a:b)';
    i = i+1;
    Nt = Nt - Nbit;
    Ind = Ind + Nbit;
    if Nt < Nbit ,
        break;
    end;
end;
Bit = Bit2(1:i-1,:);

[Nl Nc] = size(Bit);
y=0;

fid = fopen('1,5 - 1.dat','w+');
for k=1:Nl,
    i=0;
    for r=1:Nc,
        if r==Nc
            BitStr = [BitStr sprintf('%6.3f',Bit(k,r))];
        elseif i==0,
            BitStr = [sprintf('%6.3f',Bit(k,r)) ' ' ' '];
            i=1;
        else
            BitStr = [BitStr sprintf('%6.3f',Bit(k,r)) ' ' ' '];
        end;
    end;

    fprintf(fid,'%s\n',BitStr);

end;
fclose(fid);

```

APÊNDICE B

Exemplos de Sinais Profibus DP

- Rede com cabeamento normal – cabo de 1m

. 9,6 Kbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

. 19,2 Kbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

.93,75Kbps

Rede Sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

. 187,5 Kbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

. 500 Kbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

. 1,5Mbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção entre as Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

.3 Mbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Rede com Conector Desconectado

. 6 Mbps

Rede sem Problema de Comunicação

Curto-circuito entre as Linhas de Dados A e B

Interrupção das Linhas de Dados A e B

Inversão das Linhas de Dados A e B

Redes com Conector Desconectado