

UNIVERSIDADE ESTADUAL DE MARINGÁ  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**DETECÇÃO DE DEFEITOS EM CALDEIRAS  
DE RECUPERAÇÃO QUÍMICA**

Sérgio Henrique Saavedra Martinelli  
MSc. Engº Químico, UEM, 2000  
Orientador: Prof. Dr. Ivo Neitzel  
Co-orientador: Prof. Dr. Osvaldo Vieira

Tese de Doutorado submetida à  
Universidade Estadual de Maringá,  
como parte dos requisitos à  
obtenção de grau de Doutor em  
Engenharia Química, área de  
Desenvolvimento de Processos.

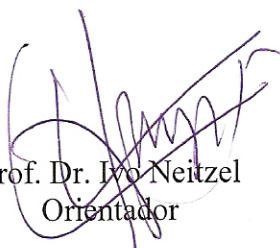
Maringá – PR - Brasil  
Agosto de 2008




UNIVERSIDADE ESTADUAL DE MARINGÁ  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

Esta é a versão final da Tese de Doutorado apresentada por Sérgio Henrique Saavedra Martinelli perante a Comissão Julgadora do Curso de Doutorado em Engenharia Química em 27 de agosto de 2008.

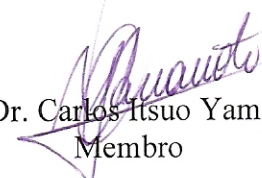
COMISSÃO JULGADORA



Prof. Dr. Ivo Neitzel  
Orientador



Prof. Dr. Osvaldo Vieira  
Co-orientador



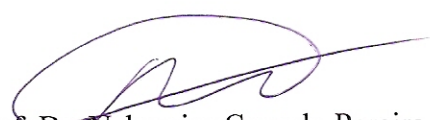
Prof. Dr. Carlos Itsuo Yamamoto  
Membro



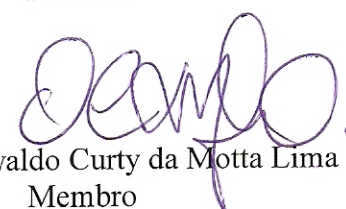
Profª Drª Fernanda de Castilhos Corazza  
Membro



Prof. Dr. Marcelo Kaminski Lenzi  
Membro



Prof. Dr. Nehemias Curvelo Pereira  
Membro



Prof. Dr. Oswaldo Curty da Motta Lima  
Membro



## **AGRADECIMENTOS**

Ao Professor e Orientador, Ivo Neitzel, pela orientação, dedicação, sabedoria, exemplo e amizade.

Ao Professor Osvaldo Vieira pelo apoio, sugestões, conselhos, exemplo e amizade.

Aos colegas de trabalho, Marcos Antônio Betini, Marcelo Gasparim e Jorge Luiz Mudri pelos ensinamentos e apoio para iniciar o trabalho neste tema.

A Klabin Papéis Monte Alegre.

E,

aos meus pais, Euza e Luiz (em memória).

aos meus irmãos, Luis e Ana, que me inspiraram para seguir a carreira de engenheiro químico.

à minha irmã, Ana, pela inspiração e apoio para ingressar no curso de doutorado.

à minha namorada, Danielli.

a Deus.



# **DETECÇÃO DE DEFEITOS EM CALDEIRAS DE RECUPERAÇÃO QUÍMICA**

**AUTOR: SÉRGIO HENRIQUE SAAVEDRA MARTINELLI**

**ORIENTADOR: PROF. DR. IVO NEITZEL**

**CO-ORIENTADOR: PROF. DR. OSVALDO VIEIRA**

Tese de Doutorado; Programa de Pós-Graduação em Engenharia Química; Universidade Estadual de Maringá; Av. Colombo, 5790, BL. E46 – 09; CEP: 87020-900 – Maringá – PR, Brasil, Defesa da Tese de Doutorado em 27 de Agosto de 2008, 143 p.

## **RESUMO**

Os processos industriais estão se tornando cada vez mais automatizados e dependentes dos componentes de controle. O caminho para melhorar a confiabilidade destes processos é garantir a confiabilidade e a robustez dos seus componentes de controle, porém um processo livre de defeitos não pode ser garantido. Os defeitos nos sistemas de controle podem se apresentar de modo abrupto ou de modo incipiente. Este último é extremamente difícil para a detecção, pois os seus efeitos são encobertos pelas variáveis manipuladas dos laços de controle. Neste trabalho, duas redes neurais artificiais são utilizadas para detecção de defeitos incipientes em uma caldeira de recuperação química, no processo de produção de celulose “kraft”. Uma rede neural perceptron multicamadas é utilizada para reproduzir o comportamento do processo. As saídas da rede são comparadas com as variáveis medidas gerando resíduos. Em seguida, outra rede neural perceptron multicamadas é utilizada para classificar os resíduos. A rede de classificação foi treinada com dados defeituosos gerados através de inclusão de erros nos sinais das variáveis de processo. Após os treinamentos, as duas redes neurais foram utilizadas para o monitoramento do processo. O método foi aplicado nas malhas de controle de vazão de ar primário, secundário e terciário, controle da temperatura da água de resfriamento das bicas de fundidos e no controle da pressão da fornalha da caldeira de recuperação química. O método apresentou taxas de alarmes falsos entre 0,2 a 5%, para as malhas analisadas. A taxa de detecção de defeitos foi de 89 a 97 %, para erros simulados de 9 a 16 % nas variáveis de processo das malhas analisadas. Pelos resultados apresentados, conclui-se que o método conseguiu detectar os defeitos de um conjunto de padrões não treinados e constitui-se uma boa ferramenta para suporte operacional.



**DEFECTS DETECTION IN CHEMICAL RECOVERY BOILERS****AUTHOR: SÉRGIO HENRIQUE SAAVEDRA MARTINELLI****SUPERVISOR: DR. IVO NEITZEL****SUPERVISOR: DR. OSVALDO VIEIRA**

Tese de Doutorado; Programa de Pós-Graduação em Engenharia Química; Universidade Estadual de Maringá; Av. Colombo, 5790, BL. E46 – 09; CEP: 87020-900 – Maringá – PR, Brasil, Defesa da Tese de Doutorado em 27 de Agosto de 2008, 143 p.

**ABSTRACT**

The industrial processes are becoming even more unmanned and dependent on the control components. The way to improve the processes reliability is to guarantee the reliability and robustness of these control components, however a defect-free process can not be guaranteed. Defects in control systems can show up in an abrupt or incipient way. The last one is extremely difficult to detect as its effects are covered up by the handled variables of the control loops. In this thesis two artificial neural networks are used to detect incipient defects in a chemical recovery boiler in the kraft pulp and paper manufacturing. A multilayer perceptron neural network is used to model the process behavior. The neural networks outputs are compared to the measurements in the process generating residues. Other multilayer perceptron neural network is used to classify the residues. The training of this classifying neural network was carried out with faulty data generated by inserting errors in the data of process variables. The method was applied in the control loops: primary, secondary and tertiary air flow, water temperature of smelt spout cooling and the furnace pressure. After the training stage, the two neural networks were used for the continuous process monitoring. The method presented false alarms rate of 0.2 to 5.0%, to the control loops analyzed. The rate of defects detection was of 89 to 97% to errors of 9 to 16% inserted at the process variables. The results presented demonstrated the method can detect correctly defects in non-trained pattern sets and constitute an alternative and reliable tool to operational support.



## SUMARIO

### LISTA DE TABELAS

### LISTA DE FIGURAS

### LISTA DE ABREVIATURAS

### NOTAÇÃO GERAL

### SÍMBOLOS PRINCIPAIS

<b>1.</b>	<b>INTRODUÇÃO .....</b>	<b>1</b>
1.1.	Introdução .....	1
1.2.	Motivação e Relevância do Trabalho .....	4
1.3.	Objetivo .....	5
1.4.	Desafios .....	5
1.5.	Publicações de Artigos .....	6
1.6.	Organização da Tese.....	7
<b>2.</b>	<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>8</b>
2.1.	Detecção de Defeitos .....	8
2.2.	Redes Neurais Artificiais .....	14
2.2.1.	Breve Introdução às RNA .....	14
2.2.1.1.	Definição das RNA .....	15
2.2.1.2.	Aplicação das RNA .....	15
2.2.1.3.	Por Que Utilizar RNA? .....	15
2.2.1.4.	Estrutura Geral das RNA .....	16
2.2.1.5.	Arquitetura das RNA .....	17
2.2.1.6.	RNA do Tipo MLP .....	17
2.2.1.7.	Determinação da Arquitetura da RNA .....	18
2.2.1.8.	Treinamento da RNA do Tipo MLP .....	18
2.2.1.9.	Função de Ativação Sigmóide das RNA do Tipo MLP .....	19
2.2.2.	Comparação Entre as Redes MLP E RBF para Problemas de Classificação Aplicados a Sistemas de Detecção de Defeitos .....	20
2.3.	Descrição do Processo .....	21



2.3.1. Resumo do Processo de Produção de Polpa Celulósica e Papel .....	21
2.3.2. Licor Negro .....	25
2.3.3. A Química da Queima do Licor Negro .....	27
2.3.3.1. Secagem .....	28
2.3.3.2. Reações de Pirólise .....	28
2.3.3.3. Reações de Queima dos Compostos Voláteis .....	29
2.3.3.3. Reações de Queima do Carbono Residual do Leito .....	29
2.3.3.5. Reações de Oxidação Inorgânica .....	30
2.3.3.6. Outras Reações na Caldeira de Recuperação Química .....	31
2.3.3.6.1. Reações de Redução de Sulfato de Sódio .....	31
2.3.3.6.2. Reações de Captura de Enxofre .....	32
2.3.3.6.3. Reações de Formação de Particulados .....	33
2.3.3.6.4. Reações de Corrosão .....	35
2.3.4. Riscos de Segurança em Caldeiras de Recuperação Química .....	36
2.3.4.1. Explosões Pelo Contato Entre Água e Fundidos .....	36
2.3.5. A Caldeira de Recuperação Química em Estudo.....	37
2.3.5.1. Fornalha .....	38
2.3.5.2. Sistema de Ar e Gases .....	42
2.3.5.3. Sistema de Resfriamento de Fundidos .....	48
2.3.5.4. Sistema de Água e Vapor .....	50
<b>3. METODOLOGIA.....</b>	<b>55</b>
3.1. Procedimento Para Treinamento .....	58
3.2. Procedimento Para Operação .....	60
<b>4. RESULTADOS E DISCUSSÃO .....</b>	<b>62</b>
4.1. Malha de Controle da Vazão de Ar Primário .....	61
4.2. Malha de Controle da Vazão de Ar Secundário .....	77
4.3. Malha de Controle da Vazão de Ar Terciário .....	89
4.4. Malha de Controle da Temperatura da Água de Resfriamento das Bicas de Fundidos .....	101
4.5. Malha de Controle da Pressão da Fornalha .....	115



4.6. Discussão .....	131
<b>5. CONCLUSÕES E SUGESTÕES DE ESTUDO .....</b>	<b>134</b>
5.1. Conclusões .....	134
5.2. Sugestões .....	134
<b>6. REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>135</b>

## **APÊNDICE A**



## LISTA DE TABELAS

Tabela 2.1: Análise elementar típica do licor negro .....	26
Tabela 2.2: Listagem das malhas da caldeira de recuperação química .....	54
Tabela 4.1: Características das variáveis para treinamento da MLP de predição da malha de controle da vazão do ar primário .....	66
Tabela 4.2: Características da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	66
Tabela 4.3: Resultados estatísticos da MLP de modelo de predição da malha de vazão do ar primário, na ausência de defeitos .....	68
Tabela 4.4: Comparação dos resultados estatísticos da MLP de predição da malha de vazão do ar primário, entre as etapas de segunda validação e treinamento, verificação e validação .....	73
Tabela 4.5: Características da MLP de classificação dos resíduos da malha de controle da vazão do ar primário .....	74
Tabela 4.6: Desempenho da MLP de classificação dos resíduos da malha de controle da vazão do ar primário .....	75
Tabela 4.7: Características das variáveis para treinamento da MLP de predição da malha de controle da vazão do ar secundário .....	79
Tabela 4.8: Características da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	79
Tabela 4.9: Resultados estatísticos da MLP de modelo de predição da malha de vazão do ar primário, na ausência de defeitos .....	81
Tabela 4.10: Comparação dos resultados estatísticos da MLP de predição da malha de vazão do ar secundário, entre as etapas de segunda validação e treinamento, verificação e validação .....	85
Tabela 4.11: Características da MLP de classificação dos resíduos da malha de controle da vazão do ar secundário .....	86
Tabela 4.12: Desempenho da MLP de classificação dos resíduos da malha de controle da vazão do ar secundário .....	87
Tabela 4.13: Características das variáveis para treinamento da MLP de predição da malha de controle da vazão do ar terciário .....	91
Tabela 4.14: Características da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	91
Tabela 4.15: Resultados estatísticos da MLP de modelo de predição da malha de vazão do ar primário, na ausência de defeitos .....	93
Tabela 4.16: Comparação dos resultados estatísticos da MLP de predição da malha de vazão do ar terciário, entre as etapas de segunda validação e treinamento, verificação e validação .....	97
Tabela 4.17: Características da MLP de classificação dos resíduos da malha de controle da vazão do ar terciário .....	98
Tabela 4.18: Desempenho da MLP de classificação dos resíduos da malha de controle da vazão do ar terciário .....	99
Tabela 4.19: Características das variáveis para treinamento da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas .....	104
Tabela 4.20: Características das variáveis para treinamento da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas .....	104



Tabela 4.21: Resultados estatísticos da MLP de modelo de predição da malha de temperatura da água de resfriamento das bicas, na ausência de defeitos .....	107
Tabela 4.22: Comparação dos resultados estatísticos da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, entre as etapas de segunda validação e treinamento, verificação e validação .....	111
Tabela 4.23: Características da MLP de classificação dos resíduos da malha de controle de temperatura da água de resfriamento das bicas .....	112
Tabela 4.24: Desempenho da MLP de classificação dos resíduos da malha de controle de temperatura da água de resfriamento das bicas .....	113
Tabela 4.25.: Características das variáveis para treinamento da MLP de predição da malha de controle da pressão da fornalha .....	119
Tabela 4.26: Características das variáveis para treinamento da MLP de predição da malha de controle da pressão da fornalha .....	120
Tabela 4.27: Resultados estatísticos da MLP de modelo de predição da malha de controle da pressão da fornalha, na ausência de defeitos .....	122
Tabela 4.28: Comparação dos resultados estatísticos da MLP de predição da malha de controle da pressão da fornalha, entre as etapas de segunda validação e treinamento, verificação e validação .....	127
Tabela 4.29: Características da MLP de classificação dos resíduos da malha de controle da pressão da fornalha .....	129
Tabela 4.30: Desempenho da MLP de classificação dos resíduos da malha de controle da pressão da fornalha .....	130
Tabela 4.31: Comparação dos resultados das MLP's de predição .....	131
Tabela 4.32: Comparação dos resultados das MLP's de classificação .....	132
Tabela 4.33: Comparação das taxas de alarmes falsos para as malhas analisadas .....	132



## LISTA DE FIGURAS

Figura 2.1: Estrutura genérica de uma rede neural artificial .....	16
Figura 2.2: Processo de produção de celulose e papel .....	23
Figura 2.3: Estágios da queima do licor negro dentro da fornalha da caldeira .....	31
Figura 2.4. A caldeira de recuperação química .....	38
Figura 2.5: Bocal de licor fora de operação .....	39
Figura 2.6: Bocal de queima de licor negro dentro da fornalha da caldeira .....	39
Figura 2.7: Posição dos bocais de licor .....	40
Figura 2.8: Bocal de licor em operação .....	40
Figura 2.9: Posicionamento das aberturas de ar, bocais de licor e queimadores de óleo .....	41
Figura 2.10: Fluxograma de controle da vazão de licor negro para a queima na caldeira .....	41
Figura 2.11: Leito de sais e alimentação de ar primário e secundário .....	43
Figura 2.12 a: Malhas de controle do sistema de ar e gases da caldeira .....	43
Figura 2.12 b: Malhas de controle do sistema de ar secundário da caldeira .....	44
Figura 2.12 c: Malhas de controle do sistema de ar terciário da caldeira .....	44
Figura 2.12 d: Malhas de controle do sistema de tiragem de gases da caldeira .....	45
Figura 2.13: Fluxo de gases na fornalha da caldeira .....	46
Figura 2.14: Desenho esquemático do fluxo de gases no superaquecedor .....	46
Figura 2.15: Desenho esquemático do fluxo de gases no economizador .....	47
Figura 2.16: Desenho esquemático do perfil de temperatura dos gases na caldeira .....	47
Figura 2.17: Desenho esquemático de uma bica de fundidos .....	48
Figura 2.18: Bica de fundidos .....	48
Figura 2.19: Fluxograma do sistema de resfriamento das bicas de fundidos .....	49
Figura 2.20: Fluxograma de água e vapor .....	50
Figura 2.21: Fluxograma de controle automático das temperaturas do ar primário e secundário .....	51
Figura 2.22: Fluxograma de controle automático do nível do balão de vapor .....	52
Figura 2.23: Fluxograma do controle automático de temperatura do vapor .....	52
 Figura 3.1: Esquema de treinamento da RNA de predição .....	 55
Figura 3.2: Esquema de geração de resíduos .....	56
Figura 3.3: Esquema de treinamento da RNA de classificação .....	57
Figura 3.4: Operação do método de detecção de defeitos .....	57
Figura 3.5: Fluxograma esquemático do procedimento para treinamento .....	60
 Figura 4.1 a: Vazão de ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	 63
Figura 4.1 b: Pressão de ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	63
Figura 4.1 c: Percentagem de corrente do motor do ventilador de ar primário, em relação à corrente nominal, para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	64



Figura 4.1 d: Temperatura do ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	64
Figura 4.1 e: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	65
Figura 4.1 f: Saída do controlador de vazão do ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	65
Figura 4.2: Estrutura da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	66
Figura 4.3: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar primário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário .....	67
Figura 4.4: Resíduos das saídas do controlador de vazão do ar primário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de vazão do ar primário .....	67
Figura 4.5 a: Vazão do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	68
Figura 4.5 b: Pressão do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	69
Figura 4.5 c: Percentual de corrente do motor do ventilador de ar primário, em relação à corrente nominal, para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	69
Figura 4.5 d: Temperatura do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	70
Figura 4.5 e: Pressão da fornalha para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	70
Figura 4.5 f: Saída do controlador de vazão do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos .....	71
Figura 4.6: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar primário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário .....	72
Figura 4.7: Resíduos das saídas do controlador de vazão do ar primário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle de vazão do ar primário .....	72
Figura 4.8: Sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar primário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da vazão do ar primário .....	73
Figura 4.9: Resíduos das saídas do controlador de vazão do ar primário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de vazão do ar primário. A faixa representa o intervalo compreendido entre a média $\pm 3$ desvios padrão .....	74
Figura 4.10: Estrutura da MLP de classificação dos resíduos da malha de controle da vazão do ar primário .....	75
Figura 4.11: Tela do sistema de detecção de defeitos do sistema de ar primário da caldeira de recuperação química .....	76



Figura 4.12: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de vazão do ar primário .....	76
Figura 4.13 a: Vazão de ar secundário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	77
Figura 4.13 b: Pressão de ar secundário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	78
Figura 4.13 c: Percentagem de corrente do motor do ventilador de ar secundário, em relação à corrente nominal, para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	78
Figura 4.13 d: Saída do controlador de vazão do ar secundário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	79
Figura 4.14: Estrutura da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	80
Figura 4.15: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar secundário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário .....	80
Figura 4.16: Resíduos das saídas do controlador de vazão do ar secundário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de vazão do ar secundário .....	81
Figura 4.17 a: Vazão do ar secundário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	82
Figura 4.17 b: Pressão do ar secundário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	82
Figura 4.17 c: Percentual de corrente do motor do ventilador de ar secundário, em relação à corrente nominal, para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	83
Figura 4.17 d: Saída do controlador de vazão do ar secundário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos .....	83
Figura 4.18: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar secundário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário .....	84
Figura 4.19: Resíduos das saídas do controlador de vazão do ar secundário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle de vazão do ar secundário .....	84
Figura 4.20: Sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar secundário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da vazão do ar secundário .....	85
Figura 4.21: Resíduos das saídas do controlador de vazão do ar secundário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de vazão do ar secundário. A faixa representa o intervalo compreendido entre a média $\pm 3$ desvios padrão .....	86
Figura 4.22: Estrutura da MLP de classificação dos resíduos da malha de controle da vazão do ar secundário .....	87



Figura 4.23: Tela do sistema de detecção de defeitos do sistema de ar secundário da caldeira de recuperação química .....	88
Figura 4.24: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de vazão do ar secundário .....	88
Figura 4.25 a: Vazão de ar terciário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	89
Figura 4.25 b: Percentagem de corrente do motor do ventilador de ar terciário, em relação à corrente nominal, para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos ..	90
Figura 4.25 c: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	90
Figura 4.25 d: Saída do controlador de vazão do ar terciário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	91
Figura 4.26: Estrutura da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	92
Figura 4.27: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar terciário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário .....	92
Figura 4.28: Resíduos das saídas do controlador de vazão do ar terciário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de vazão do ar terciário .....	93
Figura 4.29 a: Vazão do ar terciário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	94
Figura 4.29 b: Percentual de corrente do motor do ventilador de ar terciário, em relação à corrente nominal, para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	94
Figura 4.29 c: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	95
Figura 4.29 d: Saída do controlador de vazão do ar terciário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos .....	95
Figura 4.30: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar terciário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário .....	96
Figura 4.31: Resíduos das saídas do controlador de vazão do ar terciário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle de vazão do ar terciário .....	96
Figura 4.32: Sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar terciário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da vazão do ar terciário .....	97
Figura 4.33: Resíduos das saídas do controlador de vazão do ar terciário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de vazão do ar terciário. A faixa representa o intervalo compreendido entre a média $\pm 3$ desvios padrão .....	98



Figura 4.34: Estrutura da MLP de classificação dos resíduos da malha de controle da vazão do ar terciário .....	99
Figura 4.35: Tela do sistema de detecção de defeitos do sistema de ar terciário da caldeira de recuperação química .....	100
Figura 4.36: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de vazão do ar terciário .....	100
Figura 4.37 a: Temperatura da água de resfriamento na entrada das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos .....	102
Figura 4.37 b: Vazão total da água de resfriamento das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos .....	102
Figura 4.37 c: Temperatura média da água de resfriamento na saída das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos .....	103
Figura 4.37 d: Diferença de temperatura da água de resfriamento entre a entrada e a saída das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos .....	103
Figura 4.37 e: Saída do controlador de temperatura da água de resfriamento das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos ..	104
Figura 4.38: Estrutura da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos .....	105
Figura 4.39: Sinais reais e inferidos pela MLP para a saída do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de temperatura de resfriamento da água das bicas .....	106
Figura 4.40: Resíduos das saídas do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de temperatura da água de resfriamento das bicas .....	106
Figura 4.41 a: Temperatura da água de resfriamento na entrada das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos .....	107
Figura 4.41 b: Vazão total de água de resfriamento das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos .....	108
Figura 4.41 c: Temperatura média da água de resfriamento na saída das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos .....	108
Figura 4.41 d: Diferença de temperatura da água de resfriamento entre a entrada e a saída das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos .....	109
Figura 4.41 e: Saída do controlador de temperatura da água de resfriamento das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos .....	109
Figura 4.42: Sinais reais e inferidos pela MLP para a saída do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de	



segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas .....	110
Figura 4.43: Resíduos das saídas do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas .....	110
Figura 4.44: Sinais reais e inferidos pela MLP das saídas do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas .....	111
Figura 4.45: Resíduos das saídas do controlador da temperatura da água de resfriamento das bicas, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de temperatura da água de resfriamento das bicas. A faixa representa o intervalo compreendido entre a média $\pm 3$ desvios padrão .....	112
Figura 4.46: Estrutura da MLP de classificação dos resíduos da malha de controle da temperatura da água de resfriamento das bicas .....	113
Figura 4.47: Tela do sistema de detecção de defeitos do sistema resfriamento das bicas de fundidos da caldeira de recuperação química .....	114
Figura 4.48: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de temperatura da água de resfriamento das bicas .....	114
Figura 4.49 a: Vazão de sólidos totais secos do licor negro para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos .....	116
Figura 4.49 b: Pressão diferencial da caldeira para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos .....	116
Figura 4.49 c: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de pressão da fornalha, livre de defeitos .....	117
Figura 4.49 d: Corrente do motor dos ventiladores de tiragem para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle pressão da fornalha, livre de defeitos .....	117
Figura 4.49 e: Vazão de ar total para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos .....	118
Figura 4.49 f: Índice de entupimento no lado gases para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos .....	118
Figura 4.49 g: Saída do controlador da pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos .....	119
Figura 4.50: Estrutura da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos .....	120
Figura 4.51: Sinais reais e inferidos pela MLP para a saída do controlador de pressão da fornalha, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha .....	121
Figura 4.52: Resíduos das saídas do controlador de pressão da fornalha, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha .....	121



Figura 4.53 a: Vazão de sólidos totais secos do licor negro para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	122
Figura 4.53 b: Pressão diferencial da caldeira para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	123
Figura 4.53 c: Pressão da fornalha para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	123
Figura 4.53 d: Corrente do motores dos ventiladores de tiragem dos gases para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	124
Figura 4.53 e: Vazão de ar total para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	124
Figura 4.53 f: Índice de entupimento dos gases para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	125
Figura 4.53 g: Saída do controlador da pressão da fornalha para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos .....	125
Figura 4.54: Sinais reais e inferidos pela MLP para a saída do controlador da pressão da fornalha, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de pressão da fornalha .....	126
Figura 4.55: Resíduos das saídas do controlador da pressão da fornalha, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da pressão da fornalha .....	127
Figura 4.56: Sinais reais e inferidos pela MLP das saídas do controlador da pressão da fornalha, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da pressão da fornalha .....	128
Figura 4.57: Resíduos das saídas do controlador da pressão da fornalha, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da pressão da fornalha. A faixa representa o intervalo compreendido entre a média $\pm 3$ desvios padrão .....	128
Figura 4.58: Estrutura da MLP de classificação dos resíduos da malha de controle da pressão da fornalha .....	129
Figura 4.59: Tela do sistema de detecção de defeitos de controle da pressão da fornalha .....	130
Figura 4.60: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de pressão da fornalha .....	131
Figura 4.61: Taxas de detecção de defeitos das malhas analisadas .....	133



**LISTA DE ABREVIATURAS**

HMM	“Hidden Markov Model”.
IFAC	“International Federation of Automatic Control”.
MLP	Perceptron Multicamadas (“Multilayer Perceptron”).
RBF	Base Radial (“Radial Basis Function”).
RNA	Rede Neural Artificial.
SNN	“Statistica Neural Networks”.



## LISTA DE NOMENCLATURAS

a	Ativação da rede neural artificial.
$a_i, b_i, c_i$	Parâmetros da rede neural artificial.
CARP	Percentagem de corrente do motor do ventilador de ar primário da caldeira, em relação ao seu valor nominal (%).
CARS	Percentagem de corrente do motor do ventilador de ar secundário da caldeira, em relação ao seu valor nominal (%).
CART	Percentagem da corrente do motor do ventilador de ar terciário da caldeira, em relação ao seu valor nominal (%).
CLAS	Variável de classificação dos resíduos (“verdadeiro” ou “falso”).
CORV	Percentagem de corrente média dos motores dos ventiladores de tiragem de gases da caldeira (%).
CT	Medidor e transmissor de corrente do motor.
DIC	Controlador e indicador de concentração de sólidos totais.
DIFE	Diferença de temperatura da água de resfriamento entre a entrada e a saída das bicas de fundidos da caldeira (°C).
DT	Medidor e transmissor de concentração de sólidos totais.
f(a)	Função de ativação.
$F, G: z \rightarrow Y_0$	Função de entrada-saída de uma rede neural artificial.
FIC	Controlador e indicador de vazão.
FT	Medidor e transmissor de vazão.
i, j	Neurônio.
INDE	Índice de entupimento da caldeira no lado de gases (adimensional).
LIC	Controlador e indicador de nível.
LT	Medidor e transmissor de nível.
n	Dimensão.
OTAGB	Saída do controlador de temperatura da água de resfriamento das bicas de fundidos da caldeira (%).
OVARP	Saída do controlador de vazão de ar primário da caldeira (%).
OVARS	Saída do controlador de vazão de ar secundário da caldeira (%).
OVART	Saída do controlador de vazão de ar terciário da caldeira (%).
PARP	Pressão do ar primário da caldeira (mmCA).
PARS	Pressão do ar secundário da caldeira (mmCA).



PDT	Pressão diferencial.
PDTB	Pressão diferencial dos gases no banco de tubos da caldeira.
PDTBMAX	Pressão diferencial máxima dos gases no banco de tubos da caldeira.
PDTC	Pressão diferencial total no lado de gases da caldeira (mmCA).
PFOR	Pressão da fornalha da caldeira (mmCA).
PIC	Controlador e indicador de pressão.
PT	Medidor e transmissor de pressão.
RESIDUO	Resíduo, diferença entre a variável medida e inferida.
TAGEB	Temperatura da água de resfriamento na entrada das bicas de fundidos da caldeira (°C).
TAGSB1	Temperatura da água na saída da bica de fundidos nº1 da caldeira.
TAGSB2	Temperatura da água na saída da bica de fundidos nº2 da caldeira.
TAGSB3	Temperatura da água na saída da bica de fundidos nº3 da caldeira.
TAGSB4	Temperatura da água na saída da bica de fundidos nº4 da caldeira.
TARP	Temperatura do ar primário da caldeira (°C).
TARS	Temperatura do ar secundário da caldeira (°C).
TIC	Controlador e indicador de temperatura.
TMED	Temperatura média da água de resfriamento na saída das bicas de fundidos da caldeira (°C).
TSSH	Vazão mássica de sólidos totais secos do licor negro para queima na caldeira (tss/h).
TT	Medidor e transmissor de temperatura.
VAGSB1	Vazão da água na saída da bica de fundidos nº1 da caldeira.
VAGSB2	Vazão da água na saída da bica de fundidos nº2 da caldeira.
VAGSB3	Vazão da água na saída da bica de fundidos nº3 da caldeira.
VAGSB4	Vazão da água na saída da bica de fundidos nº4 da caldeira.
VARP	Vazão de ar primário da caldeira (Nm <sup>3</sup> /h).
VARs	Vazão de ar secundário da caldeira (Nm <sup>3</sup> /h).
VART	Vazão de ar terciário da caldeira (Nm <sup>3</sup> /h).
VATT	Vazão de ar total para a caldeira (Nm <sup>3</sup> /h).
VATTMAX	Vazão de ar total máxima da caldeira.
w	Pesos da rede neural artificial.
X <sub>i</sub> (k)	Medições de processo.
y	Saída do neurônio.



$Y_0$	Vetor de saída de uma rede neural artificial.
$Y_i(k)$	Valores inferidos da rede neural artificial.
$z$	Vetor de entrada de uma rede neural artificial.

## LETRAS GREGAS

$\phi_j, \psi_{ji}$	Função contínua de uma variável.
$u_a$	Nível de ativação de um neurônio.
$\sigma_i(k)$	Resíduo.



## 1. INTRODUÇÃO

### 1.1 Introdução

Os processos industriais estão se tornando cada vez mais automatizados e dependentes dos componentes de controle. O caminho para melhorar a confiabilidade destes processos é garantir a confiabilidade e a robustez dos seus componentes de controle. Porém, um processo livre de defeitos não pode ser garantido (FRANK et al., 1997). A “International Federation for Automatic Control” (IFAC) define defeito como um desvio não permitido, de pelo menos uma propriedade característica ou variável do sistema, do seu comportamento padrão, usual ou aceitável (ANGELOV et al. 2006).

Os defeitos podem ser divididos em vários tipos:

- Defeitos aditivos: são entradas desconhecidas influenciando no processo, causando mudanças em suas saídas. Eles descrevem o comportamento, por exemplo, de vazamentos em tubulações.
- Defeitos multiplicativos: são mudanças em alguns parâmetros do processo que causam mudanças em suas saídas. Esses defeitos descrevem o comportamento de deterioração dos equipamentos, como, por exemplo, a contaminação de superfícies, entupimentos ou perda parcial da pressão nas tubulações.
- Defeitos em sensores: são discrepâncias entre os valores medidos e os valores reais das variáveis do processo.
- Defeitos em atuadores: são discrepâncias entre o comando de entrada de um atuador e a sua saída real.

Os defeitos podem se apresentar de modo abrupto, ou de modo lento ou incipiente. Este último provoca uma perda gradual de desempenho do processo e é extremamente difícil para detecção, pois os seus efeitos são encobertos pelas variáveis manipuladas dos laços de controle (TINOS, 1999). A motivação inicial de se trabalhar com o monitoramento de processos químicos é que as situações de natureza crítica sempre se iniciam com sinais incipientes (ALMEIDA, 2006). Qualquer procedimento de detecção de defeitos é um teste de consistência que checa se o comportamento atual do sistema, identificado por variáveis físicas medidas, é consistente com as relações matemáticas obtidas do modelo do processo (FAGARASAN et al., 2004). A detecção de defeitos em equipamentos complexos é importante do ponto de vista estratégico, por



seus vários aspectos, como, por exemplo, evitar quebras e melhorar a gestão da manutenção dos equipamentos e diagnosticar, o mais rápido possível, as situações críticas (PARISINI, 1997). Quando os defeitos estão relacionados à segurança operacional, a detecção se torna indispensável (ANGELOV et al., 2006).

Conceitualmente, a detecção de defeitos é a indicação de que alguma coisa está errada no sistema monitorado. O isolamento do defeito é a determinação da sua exata localização, ou seja, a determinação do componente defeituoso. A identificação do defeito é a determinação da sua magnitude. As etapas de isolamento e identificação são referidas como diagnóstico de defeitos. Enquanto que a detecção e o isolamento de defeitos são necessidades em qualquer sistema prático, a sua identificação, em algumas aplicações, pode não justificar o esforço necessário. Consequentemente, a maioria dos sistemas desenvolvidos possui somente as etapas de detecção e isolamento (GERTLER, 1998).

O desempenho de um sistema de detecção de defeitos é caracterizado pela sensibilidade, velocidade e robustez. Sensibilidade pode ser conceituada pela habilidade do método para detectar defeitos de magnitudes razoavelmente pequenas. A velocidade é a habilidade do método para detectar defeitos com atraso razoavelmente pequeno, em relação à sua origem. Robustez é a habilidade do método para operar na presença de ruídos, distúrbios e erros de modelagem, com poucos alarmes falsos. Pode-se dizer que um sistema de monitoramento de processos é confiável quando ele for capaz de, ao mesmo tempo, realizar as detecções de modo precoce, discriminar as situações anormais e minimizar os alarmes falsos (ALMEIDA, 2006).

Os métodos de detecção de defeitos podem ser classificados em dois grupos, os que utilizam um modelo matemático (métodos baseados em modelos) e os que não utilizam (métodos livres de modelos) (PATAN e PARISINI, 2005).

De acordo com GERTLER (1998), os métodos de detecção de defeitos livres de modelos são: a redundância física; a utilização de sensores especiais; a checagem de limites; a análise espectral e o teste de razão lógica. A redundância física é a utilização de sensores múltiplos, que são instalados para medir a mesma variável de processo. Qualquer discrepância entre as medições indica a existência de um sensor defeituoso. Com a utilização de três ou mais sensores é possível realizar o isolamento do sensor defeituoso. Para a maioria dos processos industriais, essa alternativa se torna inviável pelos altos custos envolvidos e pela maior necessidade de espaço físico das instalações (TINOS, 1999). Sensores especiais podem ser instalados para a detecção de um defeito



específico no processo, como, por exemplo, vibração, taxa de elongação, deslocamento axial, deslocamento radial, etc. O método de checagem de limites compara as medições do processo com limites programados. Quando uma medição excede o limite programado, há a indicação de um defeito. Este método possui duas limitações: (a) se as variáveis do processo possuírem grandes variações, os limites precisarão ser ajustados em faixas muito conservadoras, diminuindo a capacidade de detecção do método; e (b) se os efeitos de um componente defeituoso se propagarem para outras variáveis haverá a geração de muitos alarmes, tornando difícil a identificação do componente defeituoso. Normalmente, os defeitos incipientes e intermitentes não são detectados pelo método de checagem de limites (ISERMANN, 2000). O método de análise espectral consiste do monitoramento da frequência espectral das variáveis do processo. Quando houver um desvio em relação aos valores normais há a indicação de um defeito. O teste de razão lógica consiste de regras lógicas, em que, para cada sintoma ou agrupamentos de sintomas, há um diagnóstico. Por exemplo, se existem um determinado sintoma X e um determinado sintoma Y juntos, significa que a situação Z está ocorrendo. Cada conclusão pode servir como um sintoma para a próxima regra, até que a conclusão final seja realizada.

Os métodos baseados em modelos utilizam um modelo matemático do processo monitorado. A diferença entre a variável estimada pelo modelo e a medida pelo processo recebe o nome de resíduo e é o indicativo da presença de um defeito. De acordo com GERTLER (1998), eles podem ser divididos em modelos baseados em estimação de parâmetros ou em redundância analítica.

A estimação de parâmetros é uma aproximação natural para a detecção e o isolamento de defeitos paramétricos (multiplicativos). Um modelo de referência é obtido pela identificação das condições do processo, na ausência de defeitos. Os desvios em relação ao modelo de referência servem como base para a detecção e o isolamento dos defeitos.

A maioria dos métodos de detecção e diagnóstico de defeitos baseados em modelos utiliza o conceito de redundância analítica. Ele pode ser conceituado pela existência de pelo menos um modelo de processo utilizado para inferir uma variável de processo, sendo este valor comparado com o valor medido pelo instrumento físico, para gerar o resíduo.

A modelagem do processo pode ser realizada a partir das leis fundamentais que regem o seu comportamento, como os balanços de massa, energia e quantidade de



movimento. Esses modelos exigem conhecimentos profundos dos fenômenos e parâmetros do processo (ALESSANDRI, 2003). A técnica de redes neurais artificiais (RNA) é uma excelente ferramenta matemática para modelar processos complexos. Elas possuem alta capacidade de aprendizagem (PATAN e PARISINI, 2005). Diferente de outras aproximações estatísticas, ela têm a vantagem de modelar relações funcionais complexas com relativa comodidade e sem a necessidade de conhecimento profundo dos fenômenos físicos envolvidos. Para a maioria das aplicações, as RNA funcionam razoavelmente bem, o que as tornam muito utilizadas em aplicações genéricas e em problemas nos quais não se conhece a melhor ferramenta para solução (HAYKIN, 1999). A RNA é utilizada para resolver problemas de classificação e de predição (VENKATASUBRAMANIAN et al., 2003). Por esses motivos, a técnica de redes neurais tem sido cada vez mais utilizada para a detecção de defeitos em processos industriais (PATAN e PARISINI, 2005).

## **1.2. Motivação e Relevância do Trabalho**

A caldeira de recuperação química na indústria de polpa celulósica e papel é um equipamento para a combustão do licor negro, um subproduto da produção de polpa celulósica que contém componentes orgânicos e inorgânicos complexos em um meio aquoso alcalino. A caldeira de recuperação química possui três funções críticas no processo de produção de polpa celulósica. Ela atua como um reator químico para a produção de sulfeto de sódio ( $\text{Na}_2\text{S}$ ) e carbonato de sódio ( $\text{Na}_2\text{CO}_3$ ), como uma caldeira para geração de vapor pela combustão do licor negro, e como um equipamento para a destruição da matéria orgânica dissolvida no licor, eliminando o descarte de efluentes. Por esses motivos ela constitui-se como equipamento chave dentro da indústria de polpa celulósica (GREEN e HOUGH, 1992).

A quantidade de controles automáticos utilizados nas caldeiras de recuperação química é relativamente alta. Apesar disso, não é comum a utilização de redundância física para todos os medidores de processo, sendo normalmente utilizada apenas para as variáveis mais críticas. Os defeitos em componentes de instrumentação podem gerar prejuízos em termos de disponibilidade do equipamento, eficácia do processo e segurança operacional. A indisponibilidade da caldeira de recuperação provoca a parada da unidade fabril, com grandes prejuízos financeiros. O desempenho do equipamento



pode ser expresso pela taxa de queima de licor negro, pela eficiência de redução do sulfato de sódio ( $\text{Na}_2\text{SO}_4$ ) para sulfeto de sódio ( $\text{Na}_2\text{S}$ ), pela eficiência térmica para geração de vapor, pela eficiência ambiental em relação ao controle das emissões atmosféricas, dentre outros. A baixa eficiência do equipamento aumenta os custos de produção. Do ponto de vista de segurança operacional, a caldeira de recuperação química possui todos os riscos associados com a queima de combustíveis fósseis e também está sujeita ao risco de explosões pelo contato entre a água e o leito de fundidos (GREEN e HOUGH, 1992). Os fundidos são compostos inorgânicos do licor negro que se acumulam na base da fornalha a altas temperaturas (geralmente entre 800 e 850 °C) (ALMEIDA, 2006). A possibilidade da presença de água na fornalha é devida a várias causas: vazamentos dos tubos da caldeira; baixa concentração de sólidos totais do licor negro; introdução inadvertida de água dentro da caldeira e vazamentos dos componentes resfriados a água (GREEN e ROUGH, 1992).

Nesta ótica, um sistema de suporte operacional que tornasse possível acessar o status do processo de forma contínua para detectar defeitos e fornecer dados validados para os sistemas de controle seria um caminho para melhorar a disponibilidade dos equipamentos e as rotinas de manutenção das fábricas (GERTLER, 1997, 1998; CHEN et al., 1996).

### **1.3. Objetivo**

O objetivo deste trabalho é propor uma metodologia, baseada em redes neurais artificiais, para a detecção de defeitos incipientes de uma caldeira de recuperação química, em tempo real, para auxiliar a operação do equipamento.

O trabalho foi aplicado na caldeira de recuperação química nº 1 da Klabin Papéis Monte Alegre.

### **1.4. Desafios**

Um dos desafios para a realização deste trabalho é a alta complexidade deste processo químico. Outro grande desafio, é o desenvolvimento do método de detecção de defeitos para um equipamento industrial em que, por possuir grande importância



econômica para o processo produtivo e por ser um processo crítico em termos de segurança operacional, não é possível a realização de testes ou alterações nas condições de operação. Além disso, algumas variáveis da caldeira, como, por exemplo, propriedades do licor negro, não são medidas em tempo real, o que dificulta a modelagem do processo. Pode-se citar também: a presença de múltiplos estados de operação em períodos curtos para modelagem; a similaridade dos sinais de períodos transientes e de condições quase-estáticas; a presença de dinâmica não-linear; a necessidade de se manter as medições confiáveis em longos períodos de operação para o treinamento das redes neurais, as incertezas e os ruídos nas medições; etc. Todos estes fatores representam grandes desafios para a obtenção de um sistema com alta capacidade para detecção de defeitos e com baixa taxa de alarmes falsos.

### **1.5. Publicações de Artigos**

Congressos.

- Martinelli, S.H.S., Neitzel, I., Vieira, O. Detecção de defeitos em sensores de uma caldeira de recuperação em uma indústria de celulose e papel. In: I TECNIQ – Seminário Sobre Tecnologia na Indústria Química - ABEQ & ABIQUIM, São Paulo, Brasil, CDROM – Artigo 98, 2006.
- Martinelli, S.H.S., Neitzel, I., Vieira, O. Detecção de defeitos via redes neurais: aplicação – sistema de resfriamento das bicas de fundidos de uma caldeira de recuperação química. In: Rio Oil & Gas, Rio de Janeiro, Brasil, 2008. (Aceite).
- Martinelli, S.H.S., Neitzel, I., Vieira, O. Detecção de defeitos via redes neurais: aplicação – sistema de ar terciário de uma caldeira de recuperação química. V Latin American Congress of Research in Cellulose and Paper - CIADICYP, Guadalajara, México, 2008. (Aceite).

Periódicos.

- Martinelli, S.H.S., Neitzel, I., Vieira, O. Detecção de defeitos via redes neurais: aplicação – sistema de resfriamento das bicas de fundidos de uma caldeira de recuperação química. Ciência e Engenharia, 2008. (Submetido).



- Martinelli, S.H.S., Neitzel, I., Vieira, O. Detecção de defeitos via redes neurais: aplicação – sistema de ar secundário de uma caldeira de recuperação química. O Papel, 2008. (Aceite).
- Martinelli, S.H.S., Neitzel, I., Vieira, O. Detecção de defeitos via redes neurais: aplicação – sistema de ar terciário de uma caldeira de recuperação química. Controle & Instrumentação, 2008. (Aceite).

## **1.6. Organização da Tese**

No capítulo 1, são introduzidos os conceitos básicos de detecção de defeitos. São apresentados o objetivo, a motivação e os desafios deste trabalho. São citadas as publicações dos artigos e a organização da tese.

No capítulo 2, é apresentada a revisão bibliográfica, com a descrição dos trabalhos publicados na área de detecção de defeitos, uma breve introdução sobre redes neurais e uma descrição sobre o processo de recuperação química e a caldeira de recuperação química.

No capítulo 3, é apresentada a metodologia utilizada para a detecção de defeitos na caldeira de recuperação química.

No capítulo 4, são apresentados os resultados e as discussões do método de detecção de defeitos aplicado às malhas da caldeira de recuperação química.

No capítulo 5, são apresentadas as conclusões e as sugestões.

No capítulo 6, são apresentadas as referências bibliográficas.

O Apêndice A apresenta um descritivo do programa Statistica Neural Networks (SNN).



## 2. REVISÃO BIBLIOGRÁFICA

### 2.1. Detecção de Defeitos

De acordo com GERTLER (1998), os métodos baseados em modelos para detecção e diagnóstico de defeitos tiveram como uma de suas origens o controle dos processos químicos, em que os balanços de massa e energia foram aplicados na reconciliação de dados e na detecção. Alguns pesquisadores pioneiros foram David Himmelblau, da Universidade do Texas (HIMMELBLAU, 1978), Richard Mah, da Universidade de Northwestern (MAH et al., 1976), George Stephanopoulos, da Universidade de Minnesota (ROMAGNOLI e STEPHANOPOULOS, 1981) e Vladimir Vaclavek, do Instituto de Tecnologia Química de Praga (VACLAVEK, 1974). Outra origem dos métodos baseados em modelos foi na pesquisa espacial, primeiramente conduzida pela NASA na década de 70. Os trabalhos foram desenvolvidos por Alan Willsky e seus colaboradores no Massachusetts Institute of Technology (WILLSKY e JONES, 1976; DECKERT et al., 1977) e por Potter e Suman (POTTER e SUMAN, 1977) na Northrop Corporation, dando origem aos conceitos das relações de paridade (CHOW e WILLSKY, 1984; LOU et al., 1986). Outros pesquisadores que desenvolveram trabalhos de destaque foram Mironovskii, em Leningrado (MIRONOVSKII, 1979), Yacov Bem-Haim (BEM-HAIM, 1980), da Tecnion em Israel, Asok Ray, da Penn State (DESAY e RAY, 1984), Mohammad-Ali Massoumnia e Wallace Vander Velde, do Massachusetts Institute of Technology (MASSOUMNIA e VELDE, 1988), N. Viswanadham e colaboradores da GE Corporate R&D, de Balgalore na Índia (VISWANADHAM et al., 1987a), Ron Patton (PATTON e CHEN, 1991), Marcel Staroswiecki, de Lille na França (STAROSWIECKI et al., 1993) e Gertler (GERTLER e SINGER, 1985 e 1990; GERTLER e LUO, 1989).

Em paralelo com estes trabalhos, vários pesquisadores avaliaram a aplicação de filtros de Kalman para resolver problemas de detecção e isolamento de defeitos. R.K. Mehra e J. Peschon, da Scientific Systems, Inc. (MEHRA e PESCON, 1991), Alan Willsky (WILLSKY, 1976), Bernard Friedland, da Singer Company (FRIEDLAND, 1979), Garry Leininger e Ramine Nikoukhah, na França (LEININGER, 1981; NIKOUKHAH, 1994) desenvolveram trabalhos de destaque.

A idéia da utilização de observadores aplicados para diagnósticos provavelmente foi desenvolvida por R.V. Beard (BEARD, 1971) e Harold Jones (JONES, 1973), do



Massachusetts Institute of Technology e Robert Clark, da Universidade de Washington (CLARK et al., 1975). Eles foram seguidos por um grande número de pesquisadores, incluindo Paul Frank de Duisburg, Alemanha (FRANK e KELLER, 1980), M.A. Massoumnia (MASSOUMNIA, 1986), N. Viswanadham (VISWANADHAM e SRICHANDER, 1987) e Jason Speyer da UCLA (WHITE e SPEYER, 1987).

Rolf Isermann e seus colaboradores de Darmstadt, Alemanha, desenvolveram trabalhos de detecção e isolamento de defeitos por meio de estimação de parâmetros (ISERMANN, 1984 e 1993; ISERMANN e FREYERMUTH, 1991). M. Basseville, A. Benveniste e colaboradores aplicaram análises estatísticas nos resíduos para a detecção de defeitos paramétricos (BASSEVILLE et al., 1987; BENVENISTE et al., 1987; ZANG et al., 1994).

TINOS (1999) propôs um método para detecção e diagnóstico de defeitos, via redes neurais artificiais, baseado no conceito de geração de resíduos e o aplicou em robôs manipuladores. Uma rede neural do tipo perceptron multicamadas (MLP, “Multilayer Perceptron”) foi utilizada para reproduzir o comportamento dinâmico do robô manipulador e outra rede neural, do tipo base radial (RBF, “Radial Basis Function”), foi utilizada para realizar a classificação dos resíduos. Dois manipuladores foram simulados em programa computacional Matlab para os testes do sistema de detecção e diagnóstico de defeitos, sendo um manipulador planar com dois graus de liberdade e um manipulador Puma 560.

Para o treinamento da rede MLP do manipulador planar com dois graus de liberdade foram simuladas trajetórias do manipulador e coletados os dados de posição, velocidade angular e torque das juntas. Foram utilizadas dez trajetórias com cinquenta amostras em cada uma delas. As trajetórias utilizadas no treinamento foram escolhidas para que a maior parte do espaço de posições das juntas fosse coberta. O objetivo foi que os padrões utilizados no treinamento fossem bastante significativos, permitindo a generalização do mapeamento para padrões não previstos. Os dados obtidos foram normalizados e, em seguida, apresentados à rede MLP. A normalização foi feita do seguinte modo: para cada variável do vetor de entradas, relacionaram-se o maior e o menor valor do conjunto de treinamento respectivamente a zero (0) e um (1). O vetor de entrada é formado pelas posições, velocidades angulares e torques das duas juntas em cada instante  $t$  e o vetor de saída é formado pelas velocidades angulares das duas juntas no instante  $t + \Delta t$ . O erro médio quadrático do MLP foi de  $5,208 \times 10^{-5}$  para o conjunto de treinamento.



Para a classificação do vetor de resíduos, foi utilizada uma rede RBF. O treinamento dessa rede é realizado a partir de dados com e sem defeitos. A geração dos dados defeituosos foi realizada por meio da simulação de duas situações: o bloqueio da junta do elo nº1 e o bloqueio da junta do elo nº2. Estes defeitos podem ter como causas, por exemplo, o travamento do motor de acionamento ou o travamento das engrenagens que ligam a junta ao motor.

Para o treinamento da RBF, foram utilizadas nove trajetórias com quarenta amostras cada. Estas trajetórias foram apresentadas à rede RBF três vezes: uma em operação normal, uma em que ocorre o defeito nº1 e uma em que ocorre o defeito nº2, perfazendo um total de 1080 padrões. A rede RBF tem quatro entradas (os resíduos e as velocidades) e duas saídas (os dois defeitos). Foram utilizados quatro métodos de treinamento: “Global Ridge Regression” (GRR); “Local Ridge Regression” (LRR); “Forward Selection” (FS) e o mapa auto-organizável de “Kohonen” (MAOK). Após a determinação dos erros quadráticos médios, foi realizado o teste de validação com 17 trajetórias não-treinadas, com 100 amostras cada. O critério de defeitos adotado considerou que, para ser caracterizado um defeito, a saída da rede RBF tem que apresentar cinco sinais seguidos maiores que 0,5. Nos testes realizados com cinquenta e uma trajetórias, o sistema de detecção e diagnóstico, com as redes RBF treinadas pelos métodos GRR, LRR, MAOK e FS, conseguiu detectar todos os defeitos. As redes GRR, LRR e MAOK não apresentaram nenhum alarme falso. A rede treinada pelo método FS apresentou um único alarme falso.

O segundo manipulador estudado foi o Puma 560, implementado em Matlab a partir da ferramenta Robotics. Para o treinamento da rede MLP, foram utilizadas cento e cinquenta trajetórias, com cinquenta e quatro amostras em cada uma delas. As variáveis de entrada da rede foram: posições, velocidades angulares e torque das três primeiras juntas (posicionamento). As variáveis de saída das redes foram as velocidades angulares das três primeiras juntas no instante  $t + \Delta t$ . O erro médio quadrático foi de  $1,5795 \times 10^{-5}$ . A geração dos dados defeituosos foi realizada por meio da simulação de defeitos: a não transmissão dos sinais de controle para a junta nº1, para a junta nº2 e para a junta nº3, individualmente. Estes defeitos podem ter como causas, por exemplo, o rompimento dos fios que ligam o sistema de controle aos atuadores, defeitos nas saídas do sistema de controle, defeitos nos atuadores das juntas e defeitos nos sistemas de engrenagens que ligam o atuador à junta.



Para o treinamento da RNA foram utilizadas quinze trajetórias, com doze amostras cada para o treinamento, considerando quatro situações: operação normal; não transmissão do sinal de controle para a junta nº1; não transmissão do sinal de controle para a junta nº2 e não transmissão do sinal de controle para a junta nº3. A rede RBF utilizada possui seis entradas (resíduos e velocidades) e três saídas (três defeitos). Os quatro métodos de treinamento foram utilizados. O teste de validação foi realizado utilizando trinta trajetórias não treinadas, com quinze amostras em cada uma delas. Com exceção do método LRR, os outros três métodos apresentaram valores de erros médios quadráticos baixos. O critério de defeitos foi adotado considerando que, para ser caracterizado um defeito, deveriam existir três valores seguidos maiores que 0,5.

O sistema de detecção de defeitos pelo método FS apresentou oito alarmes falsos e dois defeitos não foram detectados. O sistema GRR apresentou um alarme falso e todos os defeitos foram detectados. O sistema LRR apresentou sete alarmes falsos e um defeito não foi detectado. O sistema MAOK apresentou quatro alarmes falsos e todos os defeitos foram detectados.

PATAN e PARISINI (2005) desenvolveram um método para a detecção e o isolamento de defeitos por meio de RNA, e o aplicaram no processo de evaporação de uma empresa de produção de açúcar. O processo foi modelado a partir de equações físicas. Para o treinamento da RNA, foi gerado um banco de dados defeituosos pela manipulação das variáveis de processo, a partir da inclusão de fatores de erro de 5%, 10% e 20%. Os defeitos considerados foram: variação da pressão de ar para o posicionador da válvula de controle de alimentação de solução ao evaporador, variação da pressão através desta válvula de controle e a abertura completa da válvula de passagem (“by-pass”) desta válvula de controle. O primeiro defeito pode ter como causa, por exemplo, um problema na unidade de geração de ar comprimido, um alto consumo de ar comprimido na unidade fabril e o aparecimento de rupturas ou vazamentos nas tubulações de distribuição de ar. O segundo defeito pode ter como causa, por exemplo, problemas na unidade de bombeamento de solução ao evaporador, aumento da perda de carga ao longo desta tubulação ou vazamentos nesta tubulação. O terceiro defeito pode ter como causa, por exemplo, falha operacional pelo não fechamento da válvula de passagem (“by-pass”) da válvula de controle de alimentação de solução ao evaporador, durante a operação normal do processo produtivo.

Para o treinamento das redes neurais foram coletados dados de operação. O desempenho das redes foi medido a partir da soma dos erros quadráticos. O



desempenho do sistema de detecção de defeitos foi avaliado baseado nos indicadores: qualidade da modelagem, tempo de detecção (período entre o início do aparecimento do defeito até o momento da detecção), taxa de alarmes falsos, tempo de isolamento do defeito (tempo entre o início do defeito até o seu isolamento) e a taxa de isolamento falsa. Pelos resultados apresentados, todas as situações de defeito estudadas foram possíveis de serem detectadas e isoladas. Foi concluído que as RNA podem ser utilizadas para criar sistemas eficazes para detecção e isolamento de defeitos.

BUENO (2006) desenvolveu um sistema de monitoração do processo e detecção de defeitos por meio de RNA, e o aplicou em um reator químico de pesquisa (IEA-R1). Para o treinamento das RNA, foram utilizadas duas bases de dados, uma delas gerada pelo modelo fenomenológico e a outra, obtida a partir da medição das variáveis do reator durante uma semana de operação normal. Foram desenvolvidos modelos para cada uma das variáveis escolhidas. As redes neurais escolhidas foram do tipo MLP, com uma camada intermediária e treinadas pelo algoritmo de retropropagação. A rede RBF foi testada, mas não apresentou resultados satisfatórios.

Para a construção do sistema de detecção de defeitos, as redes neurais foram testadas com uma base de dados defeituosos obtidos pela inserção de erros nas variáveis de processo. As redes testadas foram capazes de detectar os defeitos simulados.

A etapa de diagnóstico dos defeitos foi desenvolvida pela utilização de lógica Fuzzy, sendo usada a ferramenta computacional Fuzzy do Matlab. O conhecimento especialista foi modelado a partir de um conjunto de regras “Se – Então” (“If – Then”), baseado nos resíduos dos medidores de temperatura. O desempenho do sistema Fuzzy foi avaliado por meio de simulações de defeitos. Os resultados obtidos mostraram que o método apresentou excelentes resultados.

RUZ-HERNANDEZ et al. (2008) apresentaram o desenvolvimento de um esquema para detecção e diagnóstico de defeitos baseado em RNA, e o aplicaram em uma planta termelétrica. O esquema é composto de duas etapas: geração de resíduos e classificação dos defeitos. RNA do tipo MLP, com uma camada intermediária, foram desenvolvidas para prever o comportamento do processo. Elas foram treinadas com dados originados de um simulador de processo, na ausência de defeitos, por meio da ferramenta NNSYSID do MATLAB. Os modelos neurais foram validados com dados de operação do processo produtivo. As redes treinadas foram utilizadas para a predição do comportamento da potência gerada na termelétrica. A geração dos resíduos foi



realizada pelo cálculo da diferença entre as medições de processo e os sinais inferidos pelas RNA.

Seis tipos de defeitos foram considerados: rompimento de tubo das paredes de água (defeito nº1); rompimento de tubo do superaquecedor (defeito nº2); defeito no controle da temperatura do vapor superaquecido (defeito nº3); pré-aquecedor regenerativo sujo (defeito nº4); variador de velocidade das bombas de água de alimentação da caldeira operando no seu valor máximo superior (defeito nº5) e válvula de óleo combustível bloqueada (defeito nº6). A base de dados na presença destes defeitos foi gerada a partir da utilização do simulador. Os resíduos foram codificados como vetores bipolares, para representar os modelos dos diferentes tipos de defeitos, sendo utilizados para treinar a RNA de classificação dos defeitos. Os resultados indicaram que a metodologia representa uma ferramenta capaz de diagnosticar um grande número de defeitos.

ALMEIDA (2006) apresentou uma metodologia, baseada na técnica modelo oculto de Markov (HMM, acrônimo de “Hidden Markov Model”), para se detectar situações anormais em caldeiras de recuperação química, ainda em estágio inicial, ou seja, antes de se alcançar uma condição indesejável. A situação monitorada foi o acúmulo de depósitos de cinzas sobre os equipamentos da sessão de transferência de calor convectivo.

A metodologia foi dividida em três etapas: identificação de modelos, definição de limites de controle e teste. O objetivo da etapa de identificação de modelos foi identificar um HMM contínuo correspondente a uma faixa de perda de carga alta. Foram coletados 1.376 pontos de operação e divididos em dois conjuntos, sendo dois terços dos dados para o conjunto de treinamento e um terço dos dados para o conjunto de validação. Na etapa de definição dos limites de controle, foi selecionado um mês em que a caldeira estava sendo operada de forma relativamente estável do ponto de vista do entupimento das sessões de transferência de calor convectivo. Esses dados foram divididos em seis conjuntos baseados em faixas de perdas de carga. O objetivo da etapa de teste foi validar (capacidade de generalização) o HMM. Foram selecionados dois períodos para a etapa de teste e identificados os seguintes aspectos na técnica de HMM: detecção precoce de situações anormais; robustez às incertezas e ruídos; adaptabilidade à dinâmica de processos, natureza explícita; desenvolvimento e implementação computacional factíveis.



Diferentemente das outras referências bibliográficas apresentadas, nesta tese, intitulada “Detecção de Defeitos em Caldeiras de Recuperação Química”, o método de detecção de defeitos, por meio de redes neurais artificiais e baseado no conceito de geração de resíduos, é aplicado em uma caldeira de recuperação química. Além disso, é desenvolvido um modelo neural para cada malha de controle de processo, que opera em laço fechado. Nesta estratégia, a saída do controlador é a variável a ser inferida, variável esta mais afetada quando do aparecimento de um defeito, para uma malha que opera em laço fechado. O método proposto também se diferencia dos demais, por exemplo, pela inclusão da etapa de segunda validação do modelo de predição e pela inclusão de análise estatística na determinação dos limites de confiabilidade dos dados para inclusão de erros na etapa de geração de dados defeituosos. A etapa de segunda validação do modelo de predição objetiva aumentar a sua robustez. A utilização de análise estatística para a geração de dados defeituosos, na etapa de treinamento do modelo neural de classificação dos resíduos, objetiva reduzir a taxa de alarmes falsos do método de detecção.

A bibliografia revisada apresenta os resultados obtidos com a aplicação da metodologia de redes neurais artificiais na detecção de defeitos em sistemas de processo, mostrando a viabilidade de aplicação da mesma na caldeira de recuperação química.

## **2.2. Redes Neurais Artificiais**

### **2.2.1 Breve Introdução às RNA**

Como não é o foco desta tese o estudo aprofundado das RNA, o objetivo deste capítulo é dar uma breve introdução ao tema. Para pesquisa mais aprofundada recomenda-se HAYKIN (1999) e BRAGA et al. (2000).



### **2.2.1.1. Definição das RNA**

RNA é um sistema processador paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. O conhecimento é adquirido pela rede a partir de um processo de aprendizagem. O armazenamento do conhecimento é feito nas conexões entre neurônios, conhecidos como pesos sinápticos (HAYKIN, 1999)

### **2.2.1.2. Aplicação das RNA**

As RNA podem ser utilizadas em várias aplicações, como, por exemplo, reconhecimento de padrões, sistemas especialistas conexionistas, controle de processos, séries temporais e monitoramento. No reconhecimento de padrões, destaca-se, por exemplo, a capacidade de reconhecimento de caracteres e de faces. Os sistemas especialistas conexionistas incluem a capacidade de realização de diagnósticos médicos baseada no conjunto de sintomas existentes. Controle de processos é a aplicação na qual se utiliza de alguma forma, uma RNA como parte do controlador do processo. Nas séries temporais, o valor de saída da rede é gerado para um tempo futuro em relação aos dados de entrada da rede. Esta aplicação é bastante útil na previsão de mercados financeiros. A RNA aplicada para monitoramento possibilita o conhecimento rápido de uma determinada variável, sendo principalmente aplicada para inferir variáveis não medidas ou em que tempo para medição é longo.

Neste trabalho, as redes neurais foram aplicadas para dois objetivos: (a) modelar o processo para gerar o vetor resíduo e (b) classificar o resíduo para determinar a existência de defeitos no processo.

### **2.2.1.3 Por Que Utilizar RNA?**

Para uma determinada aplicação, é difícil dizer que uma técnica terá um desempenho melhor do que outra, antes que elas tenham sido testadas e comparadas. Para aplicações práticas, na maioria das vezes, não há conhecimento prévio da solução.



A tarefa de testar todas as técnicas para determinar qual é a de melhor desempenho, pode consumir demasiado esforço. Além disso, em aplicações em que se deseja resolver problemas genéricos há a necessidade de utilização de apenas uma técnica. Ao procurar uma única técnica que na maioria das aplicações funcione razoavelmente bem, certos tipos de RNA são uma excelente escolha. Em particular, a rede MLP tem obtido uma imensa popularidade. Das inúmeras aplicações práticas publicadas durante a década de 1990, parece ser significativamente evidente que as redes MLP têm demonstrado possuir uma habilidade expressiva. Alguns trabalhos teóricos tentam explicar as razões para este sucesso (HAYKIN, 1999).

#### 2.2.1.4. Estrutura Geral das RNA

Uma RNA é constituída por unidades de processamento com elevado grau de conectividade, denominadas neurônios. Cada neurônio recebe as saídas  $y$  de outros neurônios e produz um sinal na forma de uma combinação afim das entradas com pesos apropriados,  $w$ . A intensidade da influência de um neurônio  $i$  em um neurônio  $j$  é modulada pelo peso  $w_{ji}$ . O sinal resultante desta combinação é denominado ativação  $\alpha$ , e a saída do neurônio é obtida processando a ativação por intermédio de uma função  $f(\alpha_j)$ , designada função de ativação. A Figura 2.1 apresenta a estrutura genérica simplificada de uma rede neural artificial.




Figura 2.1: Estrutura genérica simplificada de uma rede neural artificial.



### 2.2.1.5. Arquitetura das RNA

Os três tipos de arquiteturas de RNA mais utilizados são:

- a) redes com propagação para frente de uma camada: são compostas por uma camada de entrada e uma de saída;
- b) redes com propagação para frente de múltiplas camadas: são compostas por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída;
- c) redes com retropropagação: contém realimentação das saídas para as entradas, sendo suas saídas determinadas pelas entradas atuais e pelas saídas anteriores.

### 2.2.1.6. RNA do Tipo MLP

Para este trabalho foram utilizadas redes neurais de propagação para frente de três (3) camadas. Essa escolha advém do fato de que estas possuem maior simplicidade para implementação e que, conforme o teorema de CYBENKO (1989), elas são capazes de, desde que com número de unidades escondidas suficientes, aproximar qualquer função contínua  $f: \Re^n \rightarrow \Re^q$ , com qualquer precisão desejada. Este teorema é dado por:

Teorema: [CYBENKO, 1989] Seja  $\phi$  qualquer função de ativação contínua. Então, dada qualquer função contínua com valores reais  $f(\cdot)$ , em um subespaço compacto  $s \subset \Re^{n_p}$  e  $\varepsilon > 0$ , existem vetores  $\omega_1, \omega_2, \dots, \omega_m, \alpha, \theta$  e uma função parametrizada  $G(\xi, \omega, \alpha, \theta) \rightarrow \Re$  tal que

$$G(\xi, \omega, \alpha, \theta) = \sum_{j=1}^m \alpha_j \phi(\omega_j^T \xi + \theta_j) \quad (2.1)$$

De acordo com EFRATI (1997), a interpretação deste teorema é que uma falha na função de mapeamento da MLP é resultado de uma escolha de parâmetros inadequada ou de um insuficiente número de unidades escondidas.



### 2.2.1.7. Determinação da Arquitetura da RNA

A solução mais freqüentemente adotada para a determinação do número de camadas intermediárias de uma rede neural e do número de neurônios é por tentativa, tática do erro e acerto. Para determinação do número de neurônios na camada intermediária, encontram-se sugestões que vão desde propor um número mínimo, um (1), de neurônios e, durante a fase de treinamento, sucessivamente ampliar este número (SU et al., 1992), até partir de uma rede superdimensionada para, durante a fase de treinamento, gradativamente reduzir o seu porte. Uma rede superdimensionada pode apresentar os problemas decorrentes da sobre-parametrização da função que se pretende mapear (BHAT e MCAVOY, 1992).

### 2.2.1.8. Treinamento da RNA do Tipo MLP

Aprender é o ato que produz um comportamento diferente a um estímulo externo devido às excitações recebidas no passado. As RNA possuem a capacidade de aprender por exemplos. Se a entrada da rede for um vetor  $Z$  e a saída um vetor  $Y_0$ , a relação  $F: Z \rightarrow Y_0$  definida pela rede é sua função entrada-saída. Um dos motivos que torna atraente o uso das redes MLP é sua capacidade de aproximar funções  $G: Z \rightarrow Y$  a partir de um treinamento adequado. Treinar significa determinar os pesos  $w_{ji}$  de forma que a rede consiga reproduzir a saída  $Y$ , uma vez apresentada à entrada  $Z$  correspondente. Espera-se que, se a rede for treinada com um número conveniente de pares  $(Z, Y)$ , seja possível minimizar  $\|F - G\|$  num sentido apropriado.

A garantia básica desta possibilidade foi demonstrada por KOLMOGOROV (1992). Este teorema apenas garante a existência de uma rede que descreve a função  $f$  na forma:

$$Z \in \mathbb{R}^n, Z \equiv [z_1, z_2, \dots, z_n]^T \quad (2.2)$$

$$f(Z) = \sum_{j=1}^{2n+1} \varphi_j \left( \sum_{p=1}^n \psi_{ji}(z_i) \right) \quad (2.3)$$



em que  $\varphi_j$  e  $\psi_{ji}$  são funções contínuas de uma variável. Para uma dada dimensão  $n$  as funções  $\psi_{ji}$  são universais, isto é, não dependem de  $f$ . Somente as funções  $\varphi_j$  são específicas para a função  $f$ . O resultado de Kolmogorov foi aperfeiçoado por diversos pesquisadores, chegando-se a mostrar que  $\varphi$  pode ser uma simples constante  $c$  e  $\psi$  pode ser uma função sigmóide pertencente ao conjunto  $S(\sigma)$ :

$$\sigma: \mathbb{R} \rightarrow [0,1], \quad \lim_{t \rightarrow -\infty} \sigma(t) = 0, \quad \lim_{t \rightarrow \infty} \sigma(t) = 1 \quad (2.4)$$

$$S(\sigma) \equiv \{a_i \sigma(b_i r_i + c_i)\}, \text{ em que } a_i, b_i, c_i \text{ são parâmetros} \quad (2.5)$$

Assim, a rede pode tomar a forma:

$$f(Z) = \sigma \left( \sum_{i=1}^n w_{ki} z_i - b_k \right) \quad (2.6)$$

As situações de treinamento podem ser categorizadas em duas classes:

- Treinamento supervisionado ou associativo, em que o treinamento é realizado pelo fornecimento de variáveis de entrada associados com padrões de comportamento das variáveis de saída. O treinamento ocorre no momento em que a saída gerada pela rede, for diferente da saída desejada. A rede irá ajustar os pesos de forma a reduzir o erro e esse processo ocorrerá inúmeras vezes até que a taxa de erro esteja dentro de uma faixa considerada satisfatória.

- Treinamento não supervisionado ou auto-supervisionado, em que há classificação dos padrões similares, sem utilizar pares (entrada – saída), isto é, no treinamento da rede são usados apenas valores de entrada. A rede trabalha essas entradas e se organiza de modo a classificá-las mediante algum critério de semelhança. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entrada como elementos de classificação.

#### 2.2.1.9. Função de Ativação Sigmóide das RNA do Tipo MLP

A função de ativação não-linear sigmóide é a função mais utilizada para as RNA. Um exemplo de função sigmóide é a função logística, dada por:



$$\varphi_a(v_a) = \frac{1}{1 + \exp(-v_a)} \quad (2.7)$$

em que  $v_a$  é o nível de ativação do neurônio.

### 2.2.2. Comparação entre as Redes do Tipo MLP e Base Radial (RBF) para Problemas de Classificação Aplicados a Sistemas de Detecção de Defeitos

TINOS (1999) utilizou a rede RBF para tratar o problema de classificação para o sistema de detecção e diagnóstico de defeitos. A escolha se baseou na justificativa de que a rede MLP treinada com algoritmo de retropropagação possui a característica de posicionar as bordas de decisão muito perto da superfície que separa os padrões de treinamento pertencentes às diferentes classes. Bordas de decisão são superfícies (ou linhas para o caso de dois neurônios na entrada) no espaço de entradas nas quais a saída dos dois (ou mais neurônios) com maior ativação na última camada são iguais para o mesmo padrão. Esta característica pode gerar má-classificação dos padrões não treinados para problemas em que as superfícies que separam as diferentes classes são difíceis de serem estipuladas a partir de um conjunto limitado de padrões.

LI et al. (2001) comparou o desempenho das redes MLP e RBF para problemas de classificação aplicados a sistemas de monitoramento e diagnóstico de defeitos. Nesse trabalho, foi utilizada a ferramenta Neural Networks, versão 2.0.4, do programa comercial Matlab. Para a comparação, foi utilizada uma rede *MLP* com três camadas, treinada com algoritmo de retropropagação, e utilizando os parâmetros de treinamento: aumento da taxa de aprendizado (1,05); diminuição da taxa de aprendizado (0,7); constante de momento (0,9); razão de máximo erro (1,04). A rede neural RBF foi utilizada com funções Gaussianas. O estudo comparativo analisou vários tipos de problemas de classificação: básicos; com defeitos desconhecidos; com ocorrência de defeitos múltiplos.

Para problemas básicos de classificação foi concluído que as redes MLP e RBF geraram níveis de desempenho similares. Para problemas de classificação frente à ocorrência de defeitos desconhecidos, foi observado que as redes MLP e RBF geraram



taxa de classificação correta de 100%. Para problemas de classificação frente à ocorrência de defeitos múltiplos, foi demonstrado que ambas as redes MLP e RBF geraram desempenhos similares. A precisão global de classificação da MLP foi de 81% e, para a RBF, de 80%.

O estudo comparativo também avaliou a capacidade de memória necessária e a quantidade de processamentos realizados. Quanto à capacidade de memória, as redes RBF necessitaram de mais memória que as redes MLP. Para um micro controlador de 8 “bits”, foi necessário entre 2 a 6 % de memória adicional e, para um micro controlador de 16 “bits”, foi necessário 4 %. Quanto aos requisitos de processamento, para os casos estudados, foi observado que: (a) para a etapa de treinamento, a rede MLP realizou maior quantidade de operações de processamento que a RBF; (b) para a etapa de teste, a rede MLP realizou uma menor quantidade de operações de processamento que a RBF. Em casos em que o treinamento “off-line” seja possível e a classificação rápida seja necessária, a rede MLP é uma escolha mais apropriada. Entretanto, se a etapa de aprendizagem de forma *on-line* for requerida, a rede RBF é mais apropriada.

Como não é o foco deste trabalho a comparação do desempenho das redes MLP e RBF, devido aos bons resultados obtidos com as redes do tipo MLP para problemas de classificação no trabalho de LI et al. (2001), foi adotada, neste trabalho, num primeiro momento, a utilização das redes do tipo MLP para a classificação do resíduo. Os resultados de desempenho das redes MLP são apresentados no capítulo 4.

## **2.3. Descrição do Processo**

### **2.3.1. Resumo do Processo de Produção de Polpa Celulósica e Papel**

A principal matéria-prima para a fabricação de polpa celulósica é a fibra da madeira. As células da madeira são quimicamente heterogêneas e constituídas de uma matriz polimérica de carboidratos (principalmente polissacarídeos, como celulose e hemicelulose) e lignina, chamados de componentes estruturais. Os extrativos, as substâncias orgânicas solúveis e as substâncias inorgânicas, representam apenas uma pequena fração da composição da madeira e são chamados de componentes não estruturais.



O processo de transformação da madeira, ou de outros materiais fibrosos, em polpa celulósica recebe o nome de polpação. Esta conversão pode ser acompanhada por processo químico, mecânico ou uma combinação de ambos. O processo químico pode ser representado, de forma simplificada, como:

Madeira (fibras + lignina) + reagentes químicos = polpa celulósica + lignina solúvel.

O processo químico de fabricação de polpa celulósica que utiliza apenas uma solução de hidróxido de sódio (NaOH) é chamado de processo soda. O processo químico que utiliza uma solução de hidróxido de sódio (NaOH) e sulfeto de sódio (Na<sub>2</sub>S) recebe o nome de processo sulfato ou “kraft”. A palavra “kraft” é de origem sueca e alemã, que significa força (resistência). C. F. Dahkl de Dainzing, na Alemanha, foi quem desenvolveu o processo sulfato. Ele descobriu que adicionando sulfeto de sódio no licor de cozimento do processo soda, havia uma aceleração do processo de deslignificação, um maior rendimento do processo e a produção de fibras mais resistentes. Essas vantagens em relação ao processo soda podem ser explicadas pelo fato de que os íons de sulfeto de hidrogênio (HS<sup>-</sup>) primeiramente reagem com a lignina, enquanto que as reações de carboidratos somente são afetadas pela alcalinidade (ou seja, os íons de OH<sup>-</sup>). Por volta de 95% da produção total de polpa celulósica do Brasil é a partir do processo sulfato (BRACELPA, 2005). A Figura 2.2 apresenta o processo sulfato de produção de polpa celulósica e papel na fábrica em estudo.



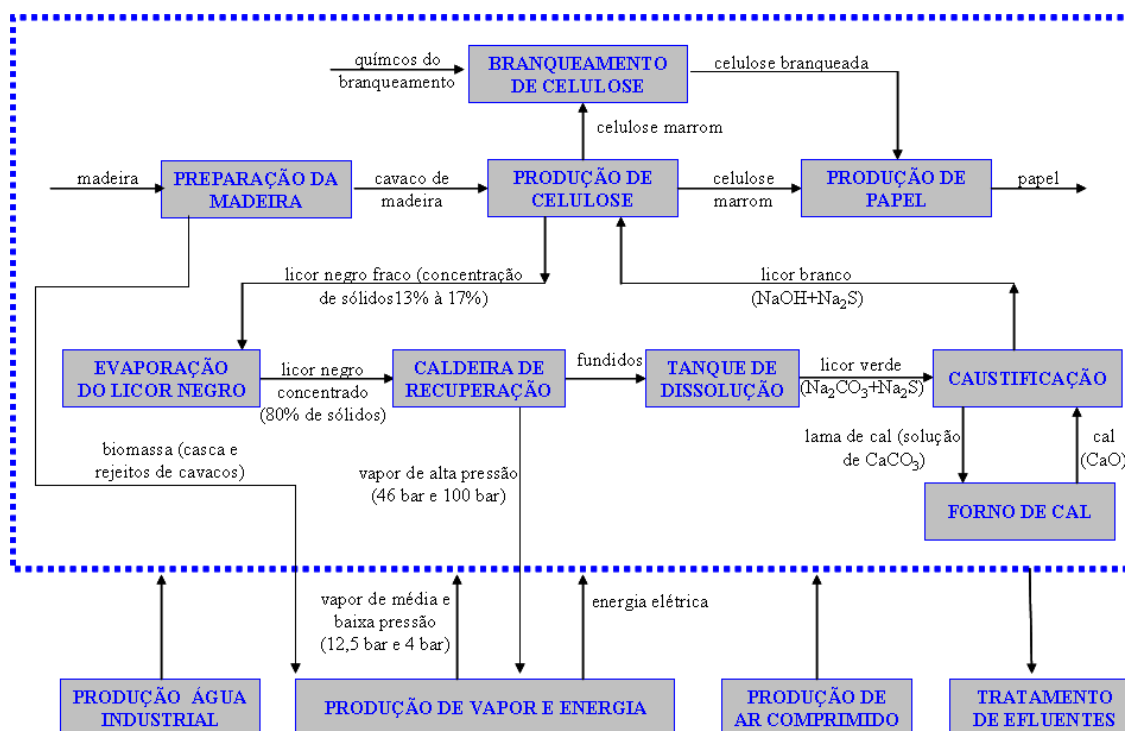


Figura 2.2: Processo de produção de polpa celulósica e papel.

Na etapa de preparação da madeira, ocorre o seu descascamento e picagem para a produção de cavacos de madeira. A casca da madeira e os rejeitos dos cavacos são aproveitados como combustível nas caldeiras de força, para a geração de vapor de alta pressão (46 bar e 100 bar). A etapa de produção de polpa celulósica transforma os cavacos de madeira em polpa celulósica marrom, por meio do cozimento da madeira com o licor branco (solução de hidróxido de sódio (NaOH) e sulfeto de sódio (Na<sub>2</sub>S)), à temperatura e pressão controladas. A cinética do processo da deslignificação da madeira é controlada pelas variáveis: tempo, temperatura e carga de álcali aplicado no cozimento. A carga de álcali pode ser definida como a percentagem de massa de hidróxido de sódio (NaOH) e sulfeto de sódio (Na<sub>2</sub>S), contidos no licor branco aplicado, em relação à massa de madeira seca. A polpa celulósica marrom pode ser transformada em papel marrom ou em polpa celulósica branqueada. Alguns tipos de papéis necessitam simultaneamente de polpa celulósica marrom e branqueada. Desta forma, pode-se afirmar, de forma simplificada, que:


Madeira (fibras + lignina) + licor branco (NaOH + Na<sub>2</sub>S) = polpa celulósica + licor negro.



Um subproduto deste processo é o resíduo do licor de cozimento, que é separado da polpa celulósica por meio de filtros. Este licor recebe o nome de licor negro fraco e será descrito posteriormente. O licor negro fraco é concentrado em evaporadores do tipo múltiplo-efeito. Este licor negro recebe o nome de licor negro concentrado e é queimado, na concentração de 80 % de sólidos totais, na caldeira de recuperação química. Em processos convencionais, o licor negro é queimado a concentração de sólidos totais entre 60 e 70 % e temperatura de 105 a 120 °C (ADAMS et al., 1997).

A caldeira de recuperação química atua como um reator químico para a produção de sulfeto de sódio ( $\text{Na}_2\text{S}$ ) e carbonato de sódio ( $\text{Na}_2\text{CO}_3$ ), como uma caldeira para a produção de vapor de alta pressão pela combustão do licor negro, destruindo a matéria orgânica presente no licor e eliminando esta corrente que iria para a estação de tratamento de efluentes (GREEN e HOUGH, 1992). O vapor de alta pressão gerado nas caldeiras é alimentado em turbogeradores para a geração de energia elétrica e de vapor de média e baixa pressão para o consumo da fábrica. A parte inorgânica do licor negro se acumula na base da fornalha da caldeira a altas temperaturas (geralmente entre 800 e 850 °C) e são chamados de fundidos ou “smelt”. Eles escoam através de aberturas na parede traseira da fornalha e são direcionados, por meio das bicas de fundidos, para o tanque de dissolução. Neste tanque, há a mistura dos fundidos com água alcalina do processo, gerando uma solução chamada de licor verde. O licor verde é composto principalmente de carbonato de sódio ( $\text{Na}_2\text{CO}_3$ ) e sulfeto de sódio ( $\text{Na}_2\text{S}$ ). Também há hidróxido de sódio ( $\text{NaOH}$ ), em menor quantidade.

A etapa de caustificação transforma o licor verde em licor branco por meio das seguintes reações químicas:



A equação (2.8) recebe o nome de reação de apagamento e transforma o óxido de cálcio ( $\text{CaO}$ ) em hidróxido de cálcio ( $\text{Ca}(\text{OH})_2$ ). Esta reação é exotérmica e há a liberação de 270 quilocalorias por cada quilograma de óxido de cálcio ( $\text{CaO}$ ) reagido. A equação (2.9) recebe o nome de reação de caustificação, e reage o hidróxido de cálcio



(Ca(OH)<sub>2</sub>) com o carbonato de sódio (Na<sub>2</sub>CO<sub>3</sub>) para produzir o hidróxido de sódio (NaOH), reagente ativo do licor branco, e o carbonato de cálcio (CaCO<sub>3</sub>). Esta reação é reversível e, mesmo com as condições mais favoráveis, a taxa de conversão é da ordem de 85 a 90 %. Embora as duas reações sejam apresentadas separadamente, elas se processam simultaneamente no reator químico denominado apagador. O carbonato de cálcio produzido (CaCO<sub>3</sub>) recebe o nome de lama de cal, após a sua separação do licor branco. O licor branco produzido, composto principalmente de hidróxido de sódio (NaOH) e sulfeto de sódio (Na<sub>2</sub>S), é utilizado para o cozimento da madeira. A lama de cal separada é lavada com água para a recuperação do hidróxido de sódio (NaOH) e sulfeto de sódio (Na<sub>2</sub>S) e, por meio de filtros, seu teor de sólidos totais é aumentado (de aproximadamente 30 % para 70 %) para a calcinação no forno de cal.

O forno de cal tem a função de produzir o óxido de cálcio a partir da calcinação da lama de cal (carbonato de cálcio, CaCO<sub>3</sub>). No forno de cal se processa a seguinte reação química:



Para consumo do processo produtivo também são produzidos água industrial e ar comprimido. Os efluentes do processo recebem tratamento de forma a atender e superar os requisitos legais.

### 2.3.2. Licor Negro

O licor negro é o combustível da caldeira de recuperação química. Ele é um subproduto da produção de polpa celulósica. Durante o cozimento da madeira, aproximadamente metade das suas substâncias se degradam e se dissolvem no licor de cozimento, gerando um licor chamado de licor negro, constituído de componentes orgânicos e inorgânicos complexos, em um meio aquoso alcalino. As substâncias da madeira dissolvidas no licor negro consistem em quatro classes: compostos de lignina (de caráter poliaromáticos), ácidos sacarínicos, ácidos orgânicos de baixa massa molecular e extrativos (resinas e ácidos graxos). Estes compostos orgânicos são combinados quimicamente com hidróxido de sódio (NaOH) na forma de sais. A parte



inorgânica do licor é composta principalmente de sódio e enxofre na forma dos compostos: hidróxido de sódio (NaOH), sulfeto de sódio (Na<sub>2</sub>S), carbonato de sódio (Na<sub>2</sub>CO<sub>3</sub>), sulfato de sódio (Na<sub>2</sub>SO<sub>4</sub>), tio-sulfato de sódio (Na<sub>2</sub>S<sub>2</sub>O<sub>3</sub>) e cloreto de sódio (NaCl). Essas substâncias químicas se originam do licor utilizado no cozimento da madeira e uma pequena quantidade entra no processo com a madeira. Uma análise elementar típica do licor negro apresenta sempre os cinco elementos: sódio (Na), enxofre (S), carbono (C), hidrogênio (H) e oxigênio (O). Em alguns casos, o potássio (K) e o cloro (Cl) também estão presentes. A Tabela 2.1 apresenta uma composição típica do licor negro (HUPA e FREDERICK, 2001).

Tabela 2.1: Análise elementar típica do licor negro.

(Fonte: HUPA e FREDERICK, 2001)

Elemento químico	Percentagem mássica dos sólidos secos (%)
C	38,2
H	3,4
O	31,1
N	0,1
S	5,2
Na	19,8
K	1,9
Cl	0,1
Outros (Ca, Si, Fe, Mg, Al, Mn)	0,2

Há uma variação considerável na relação entre sódio (Na) e enxofre (S) para diferentes processos. A utilização de sulfididade alta na polpação e sais de sódio e enxofre oxidados (Na<sub>2</sub>SO<sub>4</sub>, Na<sub>2</sub>SO<sub>3</sub>) no ciclo de recuperação aumentam a relação S/Na (HUPA e FREDERICK, 2001). A sulfididade do licor branco pode ser conceituada como a relação entre o teor de sulfeto de sódio (Na<sub>2</sub>S) e a soma dos teores das substâncias hidróxido de sódio (NaOH) e sulfeto de sódio (Na<sub>2</sub>S), multiplicado pelo fator 100:



$$\text{Sulfididade} = \frac{Na_2S}{(Na_2S + NaOH)} * 100 \quad (2.11)$$

em que,

Na<sub>2</sub>S: concentração mássica do sulfeto de sódio (Na<sub>2</sub>S) em gramas/litro, expresso como hidróxido de sódio (NaOH) ou óxido de sódio (Na<sub>2</sub>O),

NaOH: concentração mássica de hidróxido de sódio (NaOH) em gramas/litro, expresso como hidróxido de sódio (NaOH) ou óxido de sódio (Na<sub>2</sub>O).

Para o cálculo da sulfididade o sulfeto de sódio (Na<sub>2</sub>S) e o hidróxido de sódio (NaOH) devem estar expressos na mesma base química, ou como hidróxido de sódio (NaOH) ou como óxido de sódio (Na<sub>2</sub>O).

### 2.3.3. A Química da Queima do Licor Negro

O objetivo deste item é introduzir a complexidade da química do licor negro. Para estudo mais aprofundado, recomenda-se GREEN e HOUGH (1992) e GULLICHSEN e PAULAPURO (1998).

Apesar da queima do licor negro ter muitas similaridades com a queima de outros combustíveis, a química do processo é muito mais complexa, devido à função de recuperação química. Além dos elementos carbono (C), hidrogênio (H) e oxigênio (O), comuns na maioria dos combustíveis fósseis, o licor negro contém grandes quantidades de sódio (Na), potássio (K) e enxofre (S). Os produtos da queima não são apenas os gases dióxido de carbono (CO<sub>2</sub>) e água (H<sub>2</sub>O), mas, também, o carbonato de sódio (Na<sub>2</sub>CO<sub>3</sub>) e o sulfeto de sódio (Na<sub>2</sub>S). A queima envolve cinco elementos principais: sódio (Na), enxofre (S), carbono (C), hidrogênio (H) e oxigênio (O) e dois elementos em quantidades menores: potássio (K) e cloro (Cl). Os quatro maiores elementos dos gases da chaminé são nitrogênio (N), oxigênio (O), dióxido de carbono (CO<sub>2</sub>) e vapor de água (H<sub>2</sub>O), além de monóxido de carbono (CO), gases de enxofre (SO<sub>x</sub>) e compostos reduzidos de enxofre (TRS). Os principais produtos inorgânicos, o carbonato de sódio (Na<sub>2</sub>CO<sub>3</sub>) e o sulfeto de sódio (Na<sub>2</sub>S), são recuperados da fornalha na forma de fundidos. Os fundidos também podem conter compostos em quantidades menores como: sulfato de sódio (Na<sub>2</sub>SO<sub>4</sub>); sais de potássio (K-X<sup>-</sup>); cloreto de sódio (NaCl) e carbono não queimado (C). A queima do licor negro ocorre em etapas: secagem;




pirólise; queima de compostos voláteis; queima do carbono residual do leito e oxidação inorgânica.

### 2.3.3.1. Secagem

Na etapa da secagem, a maior parte da água presente no licor é evaporada. Ela se processa em um a dois segundos, para uma gotícula de tamanho médio entre um e dois milímetros. A gotícula de licor incha, tipicamente por um fator de 1,5 do diâmetro. A temperatura aumenta rapidamente para 150 °C durante o início da secagem.

### 2.3.3.2. Reações de Pirólise

A pirólise é uma série gradual de reações de degradação irreversíveis que o licor negro sofre à medida que a sua temperatura é aumentada. As reações de pirólise produzem gases combustíveis e carbono residual que se deposita na base da fornalha na forma de um leito. Esta reação se processa a partir da temperatura de 200 °C, nas gotículas de licor, podendo ser representada pela reação abaixo:



Os gases da pirólise incluem o hidrogênio (H<sub>2</sub>), o monóxido de carbono (CO), dióxido de carbono (CO<sub>2</sub>), vapor de água (H<sub>2</sub>O), outros compostos orgânicos e hidrocarbonetos de alto peso molecular, e os compostos reduzidos de enxofre (TRS). Os compostos reduzidos de enxofre incluem o sulfeto de hidrogênio (H<sub>2</sub>S), metilmercaptana (CH<sub>3</sub>SH), dimetilsulfeto (CH<sub>3</sub>SCH<sub>3</sub>) e dimetildissulfeto (CH<sub>3</sub>SSCH<sub>3</sub>). Eles agem como combustíveis na fornalha.

A pirólise possui as seguintes características:


- Os compostos inorgânicos presentes nos fundidos são formados pela decomposição de compostos orgânicos, durante a pirólise;
- A etapa da pirólise governa a separação dos gases e do carbono residual do leito;



- A pirólise tem um efeito importante no arraste de partículas em suspensão para fora da fornalha, devido ao inchamento das gotículas do licor;
- Algumas misturas explosivas dos gases da pirólise podem se formar dentro da fornalha, dependendo das suas condições.

#### 2.3.3.3. Reações de Queima dos Compostos Voláteis

As reações de combustão dos gases voláteis produzidos pelas reações de pirólise são relativamente rápidas, homogêneas, na fase gás e podem ser representadas conforme abaixo:




As condições necessárias para garantir combustão completa são: disponibilidade de ar suficiente, mistura adequada entre combustível e ar (turbulência) e temperaturas altas para que as reações se processem (760 a 815 °C).

#### 2.3.3.4. Reações de Queima do Carbono Residual no Leito

O leito consiste de uma mistura de compostos inorgânicos, como o carbonato de sódio ( $Na_2CO_3$ ), o sulfeto de sódio ( $Na_2S$ ), o sulfato de sódio ( $Na_2SO_4$ ) e carbono (C). A queima do carbono residual no leito consiste de duas etapas: a conversão do carbono fixo para monóxido de carbono (CO) e dióxido de carbono ( $CO_2$ ), e mudanças no estado de oxidação dos compostos inorgânicos de enxofre. As principais reações químicas envolvidas no leito são:







### 2.3.3.5. Reações de Oxidação Inorgânicas

A única reação de combustão inorgânica significativa é a oxidação do sulfeto para sulfato. Esta reação é dada por:



$\Delta H = +12.911$  kJ/kg de  $Na_2SO_4$  reagido

É uma reação exotérmica. A oxidação do sulfeto tende a ser inibida pela presença de carbono fixo (C) no leito, mas ocorrerá rapidamente quando os fundidos forem expostos ao oxigênio ( $O_2$ ), na ausência de carbono (C) no leito.

A Figura 2.3 apresenta um desenho esquemático dos estágios de queima dentro da fornalha de uma caldeira de recuperação.






Figura 2.3: Desenho esquemático dos estágios da queima do licor negro dentro da fornalha da caldeira.

### 2.3.3.6. Outras Reações na Caldeira de Recuperação Química

#### 2.3.3.6.1. Reações de Redução do Sulfato de Sódio

Uma das mais importantes funções da caldeira de recuperação química é produzir sulfeto de sódio ( $\text{Na}_2\text{S}$ ) a partir das quantidades de sódio (Na) e enxofre (S), presentes no licor negro. O sulfeto é o estado mais reduzido que o enxofre pode assumir, e a combustão é um processo essencialmente de oxidação. Consequentemente pode parecer que é um conflito produzir sulfeto de sódio ( $\text{Na}_2\text{S}$ ) e, ao mesmo tempo, processar as reações de combustão. Porém, isso não é um problema. A reação dos compostos oxidados de enxofre (S) e sódio (Na) com os agentes redutores é o mecanismo dominante pelo qual o sulfeto de sódio ( $\text{Na}_2\text{S}$ ) é formado na fornalha. Um grande número de agentes redutores está presentes na fornalha da caldeira de recuperação química, incluindo o carbono (C), o monóxido de carbono (CO) e o gás hidrogênio ( $\text{H}_2$ ). Destes, o carbono é o agente redutor mais importante. A redução do sulfato de sódio ( $\text{Na}_2\text{SO}_4$ ) a sulfeto de sódio ( $\text{Na}_2\text{S}$ ), por meio da reação com o carbono (C), é uma reação endotérmica.





$\Delta H = -1.205$  kJ/kg de  $Na_2SO_4$  reagido




$\Delta H = -3.580$  kJ/kg de  $Na_2SO_4$  reagido

As taxas das reações de carbono-sulfato são altamente sensíveis à temperatura. Se as reações de redução ocorrerem na ausência de fonte de calor, ocorrerá a redução da temperatura da fornalha. Quando as reações de queima de compostos voláteis ocorrem, elas mantêm a temperatura da fornalha alta o suficiente para proporcionarem altas taxas de reações de redução do sulfato de sódio ( $Na_2SO_4$ ). Além disso, o calor liberado pela reação de oxidação do sulfeto de sódio ( $Na_2S$ ) é maior que o calor absorvido pelas reações de redução do sulfato de sódio ( $Na_2SO_4$ ). Portanto, a temperatura da fornalha tende a aumentar, e quanto maior a temperatura da fornalha, maior será a taxa de redução do sulfato de sódio ( $Na_2SO_4$ ). O carbono (C), intimamente misturado com os compostos inorgânicos no leito, é suficiente para manter o ambiente redutor nos fundidos e nas interfaces do leito. Logo, as condições para se obter alta eficiência de redução são: a) queima na parte inferior da fornalha para manter a temperatura alta nesta região e b) manter um reservatório de carbono (C), o leito na base da fornalha, evitando o contato dos fundidos com o oxigênio ( $O_2$ ).

#### 2.3.3.6.2. Reações de Captura do Enxofre

O enxofre (S) sai da caldeira de recuperação química por meio dos fundidos, como sulfeto de sódio ( $Na_2S$ ) e sulfato de sódio ( $Na_2SO_4$ ), e pelos gases da chaminé, como compostos reduzidos de enxofre (TRS) ou dióxido de enxofre ( $SO_2$ ). A retenção de enxofre nos fundidos é normalmente de 95%. Este valor pode ser maior, e é altamente dependente das condições de operação da fornalha. A química envolvida na retenção de enxofre é descrita nas reações abaixo:








em que,

$H_2S$ : sulfeto de hidrogênio,

$MeSH$ : metilmercaptana,

$MeSMe$ : dimetilsulfeto,

$MeSSMe$ : dimetildissulfeto.







A equação (2.23) mostra que os compostos reduzidos de enxofre (TRS) podem ser formados pelas reações de pirólise do licor negro e devem ser oxidados para a forma de dióxido de enxofre ( $SO_2$ ), para descarte nos gases de chaminé, conforme mostra a equação (2.24). Este processo de oxidação requer a utilização de ar em excesso para completar a combustão. Entretanto, o dióxido de enxofre ( $SO_2$ ) pode ser capturado pela reação com as partículas de carbonato de sódio ( $Na_2CO_3$ ), evitando a perda pelos gases da chaminé, conforme mostra a equação (2.26). O produto final da reação é o sulfato de sódio ( $Na_2SO_4$ ), recuperado por um precipitador eletrostático e misturado no licor negro. A taxa de captura do enxofre (S) é determinada pela existência de partículas de carbonato de sódio ( $Na_2CO_3$ ) nos gases da caldeira, visto que essas partículas são pequenas e altamente reativas. Essa condição pode ser obtida mantendo-se altas temperaturas nas partes baixas da fornalha, provocando desta forma altas taxas de vaporização do sódio (Na), conforme mostra a equação (2.25). Pode-se afirmar que à medida que a temperatura é aumentada, a vaporização do sódio aumenta exponencialmente. Portanto, uma das maneiras de se manter baixo o teor de dióxido de enxofre ( $SO_2$ ) nos gases da chaminé é manter a temperatura da fornalha alta.



### 2.3.3.6.3 Reações de Formação de Particulados

Particulado é o nome dado a partículas finas produzidas pela vaporização de sódio (Na) e potássio (K) na fornalha. A química básica da formação de particulados é apresentada abaixo:



Todas as reações são análogas para o potássio. As reações de vaporização de sódio são endotérmicas, ou seja, a produção de particulados é limitada pela ausência de fonte de calor. Os particulados representam ao mesmo tempo um benefício e um problema para a caldeira de recuperação química. Apesar do carbonato de sódio ( $\text{Na}_2\text{CO}_3$ ) ser o elemento essencial para capturar o dióxido de enxofre ( $\text{SO}_2$ ), ele também provoca uma tendência de entupimentos nas passagens dos gases entre os tubos, principalmente na região do banco de tubos em caldeiras de dois balões, e provoca a necessidade de se ter um precipitador eletrostático de maior capacidade para a coleta dos particulados formados na caldeira. Esses entupimentos geram a necessidade de paradas não programadas nas caldeiras para limpeza. Em relação às reações de cloreto de sódio ( $\text{NaCl}$ ), e também de cloreto de potássio ( $\text{KCl}$ ), verifica-se que estes podem se vaporizar como sal. Esta característica de volatilidade é a razão pelo qual os particulados da caldeira tendem a ser enriquecidos com cloro (Cl) e potássio (K). A



presença de cloro (Cl) e potássio (K) nos particulados aumenta a taxa de corrosão nos tubos da caldeira e, além disso, abaixam o ponto de fusão dos particulados gerando maior nível de entupimentos nas passagens dos gases entre os tubos da caldeira.

#### **2.3.3.6.4. Reações de Corrosão**

As reações de corrosão, no lado dos gases, ocorrem por meio de vários mecanismos:

- a) Pelo contato direto entre os fundidos e os metais da caldeira: os fundidos reagem rapidamente com o ferro e o aço e o contato prolongado destruirá o metal. O ataque dos fundidos é prevenido pelo resfriamento do metal para formar uma camada solidificada, que age como uma barreira protetora contra os fundidos.
- b) Pelo ataque corrosivo do enxofre elementar: a taxa de corrosão do aço carbono é baixa para temperaturas abaixo de 310°C, mas aumenta rapidamente acima deste valor. A corrosão por este mecanismo pode ser controlada mantendo baixas as temperaturas do metal. A temperatura superficial dos tubos de metal é dependente do fluxo de calor local, circulação da caldeira, depósitos internos e temperatura de saturação da água da caldeira que é dependente da pressão de operação. Este tipo de corrosão não ocorre na mesma taxa para o aço inoxidável, onde são necessárias temperaturas maiores que 482°C. Por esta razão, os tubos de materiais compostos ou tubos com cromo (Cr) em sua estrutura são muitas vezes utilizados nas partes baixas da fornalha. A corrosão nos superaquecedores também ocorre por esse mecanismo se os sólidos não-queimados do licor negro são componentes dos depósitos presentes nestes tubos.
- c) Pelo ataque do sulfato de sódio ( $\text{Na}_2\text{SO}_4$ ), sulfato ácido de sódio ( $\text{NaHSO}_4$ ) e piro-sulfato de sódio ( $\text{Na}_2\text{S}_2\text{O}_7$ ): o sulfato de sódio ( $\text{Na}_2\text{SO}_4$ ) pode ser agressivo ao metal acima de 550°C.
- d) Pela corrosão ácida do dióxido de enxofre ( $\text{SO}_2$ ) nos gases quando estes atingem o ponto de orvalho: ocorre a geração de ácidos corrosivos nas partes frias, como nos dutos de saída dos gases, nos ventiladores de tiragem induzida e nos precipitadores. Para evitar esse mecanismo, não se deve trabalhar com a temperatura dos gases próxima ao ponto de orvalho.
- e) Pelo ataque do vapor de sódio condensado nas aberturas das portas de ar e outras partes frias da caldeira.



### **2.3.4. Riscos de Segurança em Caldeiras de Recuperação Química**

As caldeiras de recuperação química possuem todos os riscos associados a uma caldeira convencional, mas também estão sujeitas aos riscos de explosão pelo contato de água com o leito de fundidos em sua fornalha.

#### **2.3.4.1. Explosões pelo contato entre água e fundidos**

As explosões provocadas pelo contato entre água e os fundidos são explosões físicas, causadas pela geração extremamente rápida de vapor. A vaporização provoca uma expansão de volume e um rápido aumento de pressão, gerando uma onda de choque. Estima-se que um (1) quilograma de água vaporizando em 0,001 segundo equivale a energia mecânica de meio (0,5) quilograma de dinamite. O fator mais importante na violência da explosão de fornalhas de caldeiras de recuperação química é a quantidade de água envolvida. As causas destas explosões são:

- a) Vazamentos de tubos da caldeira: são as causas mais comuns de explosões pelo contato entre água e fundidos, principalmente se os vazamentos ocorrerem em tubos do piso e da parede da fornalha e tubos da cortina de água. Os vazamentos em tubos dos superaquecedores, normalmente, não são causas de explosão devido ao grau de superaquecimento do vapor. Os vazamentos no banco de tubos podem gerar explosões dependendo da posição em relação à proximidade com a fornalha. Os vazamentos em tubos dos economizadores normalmente não são causas de explosões devido à distância com a fornalha e o direcionamento dos gases em fluxo contrário.
- b) Baixa concentração de sólidos totais do licor negro para queima: é a segunda maior causa das explosões pelo contato entre água e fundidos. Não é recomendada a queima de licor negro com concentração de sólidos totais abaixo de 58%, sendo recomendada a instalação de medidores de concentração de sólidos totais no licor negro, na tubulação de entrada da caldeira. As causas para a queda da concentração do licor negro são variadas, incluindo, problemas nos evaporadores, vazamentos em selos de bombas, vazamentos de tubos da caldeira, fazendo com que entre água nos coletores de cinzas da caldeira e, posteriormente, nos tanques de mistura de licor, etc.
- c) Introdução de água inadvertidamente dentro da caldeira de recuperação: é outra causa comum de explosões. É provocada pela entrada de água a partir de equipamentos



auxiliares, entrada de condensado em gases não condensáveis, vazamentos nos aquecedores de ar, conexões de água com os sopradores de fuligem e lavagens após a parada. Durante o reinício do equipamento, todas as conexões de água de lavagem devem ser desconectadas.

d) Falhas de outros componentes resfriados a água: o sistema de resfriamento das bicas de fundidos se encaixa neste item.

O tanque de dissolução também possui os riscos de explosão pelo contato entre água e fundidos devido a sua característica de operação. O risco de explosão é prevenido pela quebra do fluxo de fundidos em partículas muito pequenas com uso de vapor para evitar que os fundidos se acumulem no fundo do tanque. A operação segura do tanque de dissolução exige: operação correta do vapor de atomização dos fundidos, manter o fluxo de fundidos para o tanque de dissolução o mais estável possível, manter agitação adequada no tanque de dissolução, manter um nível adequado de licor verde no tanque de dissolução, manter a concentração do licor verde no tanque de dissolução de forma a evitar a cristalização dos fundidos.

### **2.3.5. A Caldeira de Recuperação Química em Estudo**

A caldeira de recuperação química em estudo possui a capacidade de queima de licor negro de 2.000 toneladas de sólidos secos por dia, gerando vapor a 46 bar-g de pressão e 430°C de temperatura. Sua capacidade bruta para a geração de vapor é de 268 toneladas por hora. É uma caldeira de fundo inclinado para escoamento dos fundidos, possuindo dois balões (balão de vapor e balão de água). A Figura 2.4 apresenta de forma simplificada a caldeira de recuperação química.



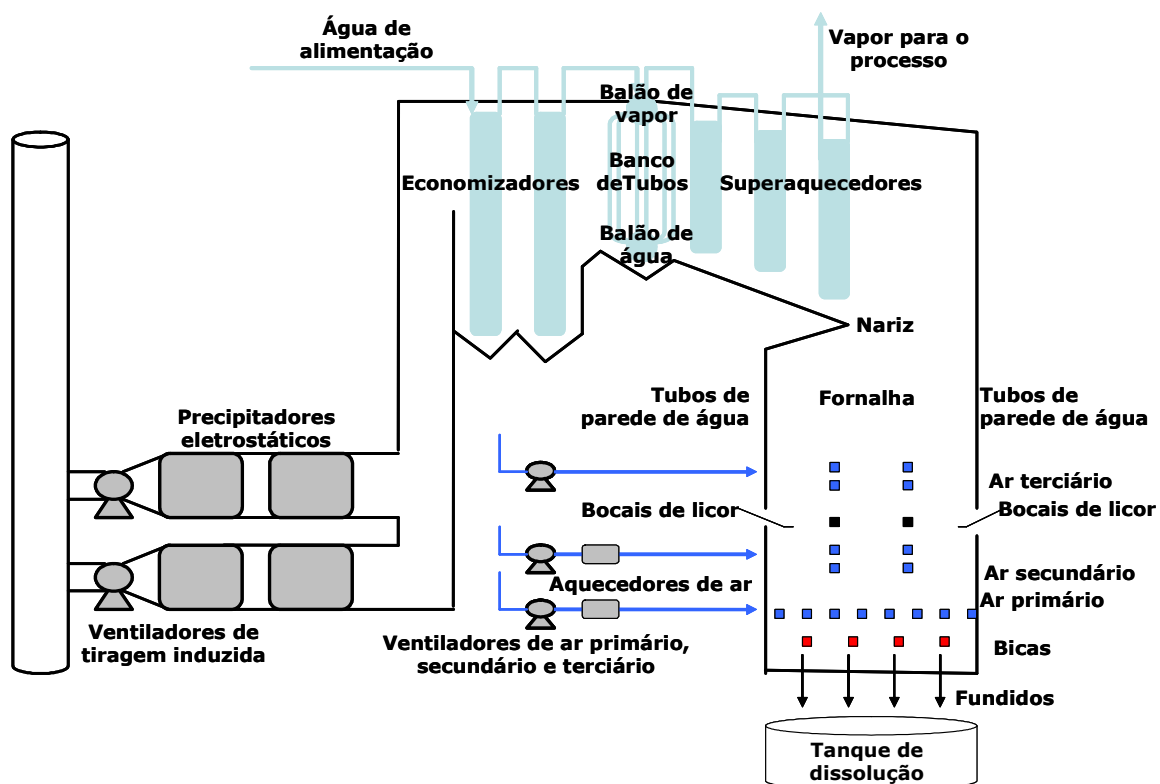


Figura 2.4. Desenho esquemático da caldeira de recuperação química.

### 2.3.5.1. Fornalha

A fornalha é a câmara retangular para a combustão do licor negro e se estende até o nariz. O nariz da caldeira tem o objetivo de proteger o superaquecedor das altas taxas de transferência de energia por radiação da fornalha e para direcionar o fluxo dos gases para os superaquecedores. Ela é composta por paredes de tubos de água e coletores. A alimentação de licor negro é realizada por meio de bocais de queima localizados nas quatro paredes da fornalha, sendo dois em cada parede lateral, um na parede frontal e um na parede traseira. O objetivo dos bocais de licor é quebrar o fluxo de licor negro em um spray de gotículas de tamanho pequeno, tipicamente entre 0,5 mm a 5,0 mm. À medida que a concentração de sólidos totais do licor aumenta é comum aumentar a temperatura de queima para controlar a viscosidade do licor. O aumento da temperatura compensa o aumento da concentração de sólidos do licor, para manter estável o tamanho das gotículas de licor na queima (ADAMS et al., 2001). A Figura 2.5 mostra um bocal de licor do tipo “splashplate”, que consiste de uma seção que direciona



o licor negro para uma superfície plana, onde é utilizada uma placa circular unida ao bocal.



Figura 2.5: Bocal de licor fora de operação.

A Figura 2.6 apresenta o posicionamento do bocal de queima de licor negro no interior da fornalha.




Figura 2.6: Bocal de queima de licor negro dentro da fornalha da caldeira.

(Fonte: TAPPI, 2001)

A Figura 2.7 apresenta o posicionamento dos bocais em uma das paredes e a Figura 2.8 apresenta um bocal em operação.





Figura 2.7: Posição dos bocais de licor.



Figura 2.8: Bocal de licor em operação.

A Figura 2.9 apresenta um desenho esquemático do posicionamento das aberturas de ar, dos bocais de licor e dos queimadores de óleo nas paredes da caldeira.



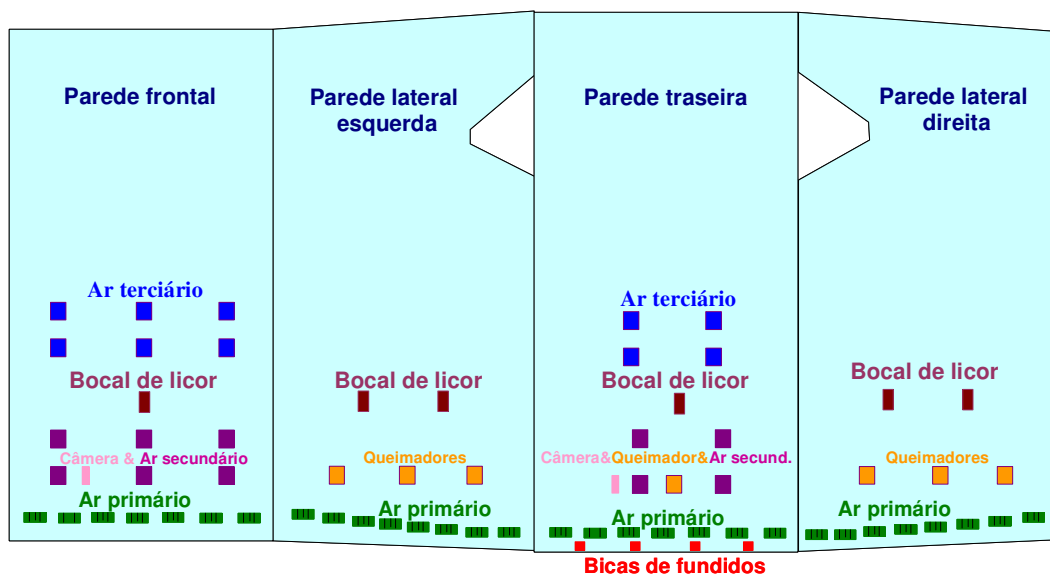


Figura 2.9: Desenho esquemático do posicionamento das aberturas de ar, bocais de licor e queimadores de óleo.

A Figura 2.10 apresenta o fluxograma de controle da vazão de licor negro para a queima na caldeira.

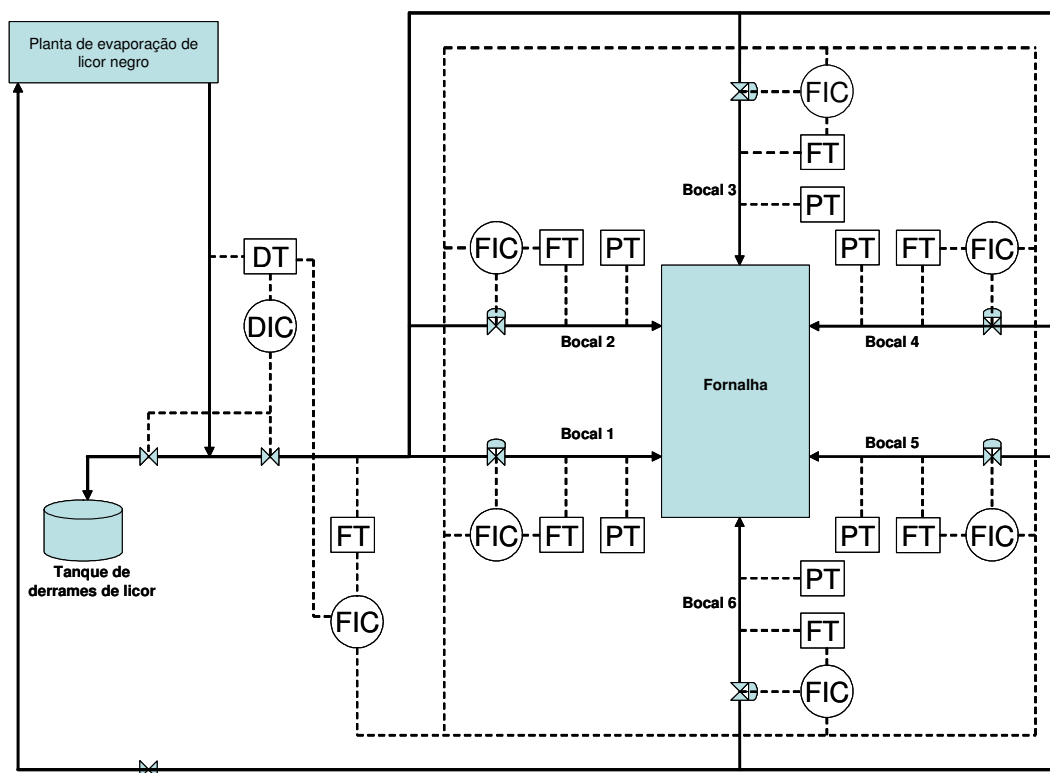


Figura 2.10: Fluxograma de controle da vazão de licor negro para a queima na caldeira.



O licor do processo de evaporação alimenta a caldeira de recuperação. Há um medidor de concentração do licor negro (indicado como DT). O sistema está programado para, em caso de concentrações de sólidos totais no licor negro abaixo de 62%, fechar a válvula de alimentação de licor para a caldeira. Há uma medição de vazão total do licor para a caldeira. O controlador de vazão total de licor recebe os sinais de vazão volumétrica total e de concentração do licor e calcula a vazão mássica total dos sólidos secos do licor. O controlador compara esse valor com o valor objetivo e envia um sinal de objetivo para os controladores individuais de vazão de licor para os bocais. Estes controladores manipulam as válvulas de controle de vazão para os bocais.

#### **2.3.5.2. Sistema de Ar e Gases**

O ar de combustão entra em três níveis, sendo denominado ar primário, secundário e terciário. A principal razão para esta divisão são as funções antagônicas de proporcionar um ambiente oxidante (rico em oxigênio), para se queimar a matéria orgânica do licor, e, ao mesmo tempo, de promover um ambiente redutor (deficiente em oxigênio), para se reduzir a parte inorgânica do licor (ADAMS et al., 1997). O ar primário tem as funções de controlar o formato e a posição do leito de sais e fornecer oxigênio para a combustão do carbono residual. A injeção deste ar ocorre nas quatro paredes da caldeira e há um ventilador dedicado para sua alimentação. As funções do ar secundário são: controlar a altura e manter a temperatura do leito; secar e queimar o licor; queimar os produtos voláteis oriundos da combustão do licor e controlar a velocidade dos gases. O ar secundário é injetado na parede frontal e na parede traseira, com um ventilador dedicado para sua alimentação. O ar terciário tem a função de queimar os produtos voláteis, manter uma selagem na fornalha (para se minimizar o arraste de material particulado para a parte superior da caldeira) e uniformizar o fluxo de gases para a sessão superior. Ele é injetado na parede frontal e na parede traseira, com um ventilador dedicado para sua alimentação.

Na base da fornalha, há a formação de um leito de sais composto de carbono e produtos inorgânicos da combustão do licor negro. A Figura 2.11 apresenta um desenho esquemático do formato do leito de sais, nas vistas traseira e lateral da caldeira de recuperação química.



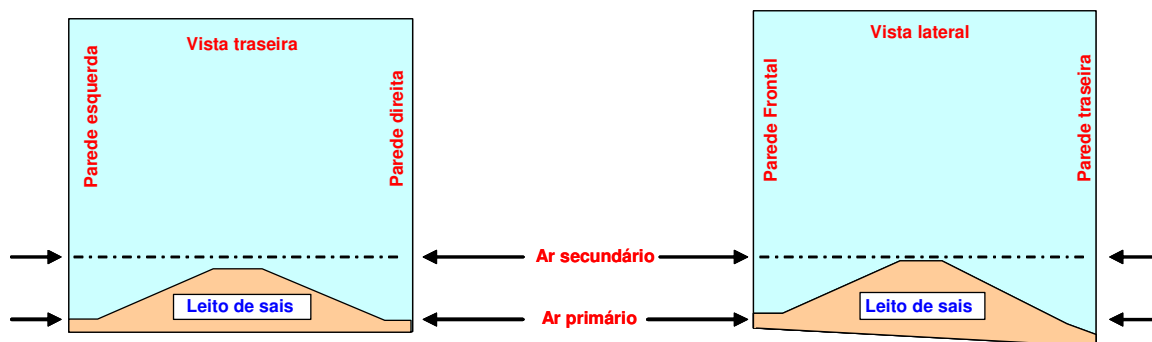


Figura 2.11: Desenho esquemático do leito de sais e alimentação de ar primário e secundário.

A alimentação de ar é realizada pelos ventiladores de ar primário, secundário e terciário, sendo o controle das suas vazões realizado automaticamente por controladores de ar primário, secundário e terciário. A partir da comparação entre as vazões medidas e os valores objetivos, os controladores de vazão de ar atuam nos posicionadores dos ventiladores. As Figuras 2.12 (a, b, c, d) apresentam as malhas de controle do sistema de ar e gases da caldeira de recuperação química. O ar primário possui as indicações de vazão (FT), temperatura (TT) e pressão (PT) do ar primário, corrente (CT) do motor do ventilador. O sinal de saída do controlador de vazão de ar primário também é disponível. As medições são idênticas para o ar secundário. O ar terciário possui medições de vazão (FT) e pressão (PT) e a corrente (CT) do motor do ventilador.

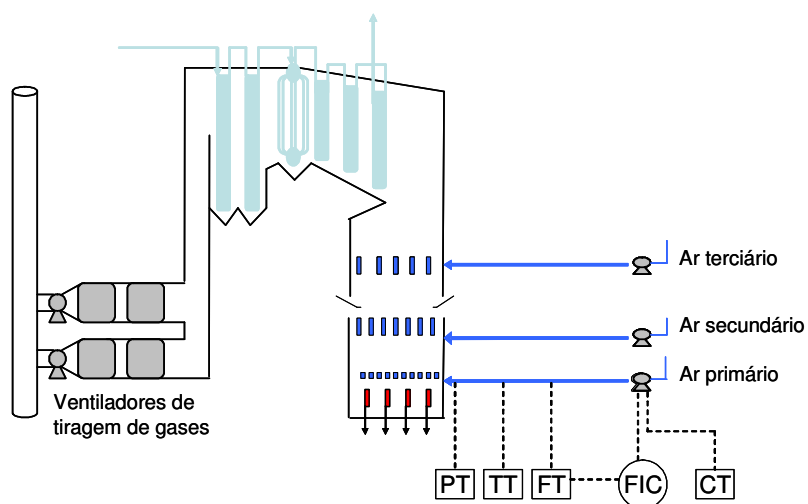


Figura 2.12 a: Malhas de controle do sistema de ar primário da caldeira.



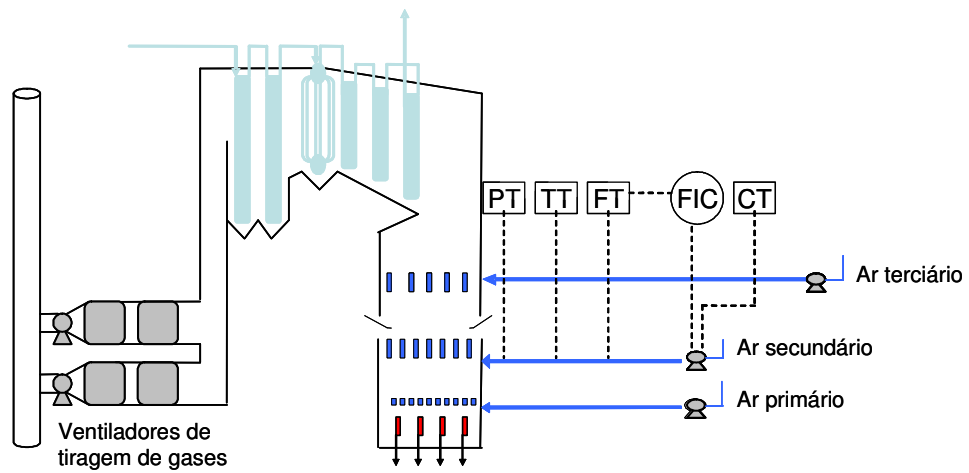


Figura 2.12 b: Malhas de controle do sistema de ar secundário da caldeira.




Figura 2.12 c: Malhas de controle do sistema de ar terciário da caldeira.



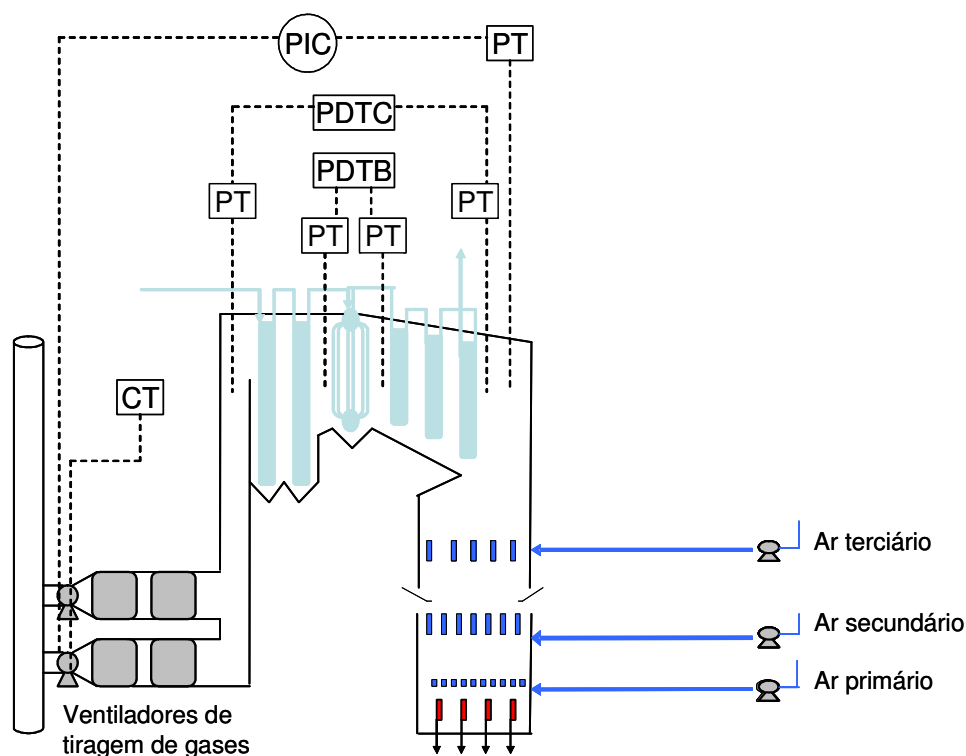


Figura 2.12 d: Malhas de controle do sistema de tiragem de gases da caldeira.

Os gases que saem da fornalha trocam calor com os superaquecedores primário e secundário, transformando o vapor saturado em superaquecido. Após os superaquecedores, os gases trocam calor com o banco de tubos, transformando a água em vapor saturado. Na sequência, os gases aquecem a água de alimentação nos economizadores nº1 e nº2, e, em seguida, passam pelos precipitadores eletrostáticos. A caldeira possui quatro câmaras de precipitadores para reduzir o teor de material particulado nos gases da chaminé. O controle automático da pressão da fornalha é realizado pelos dois ventiladores de tiragem induzida. Esses ventiladores estão localizados na saída dos precipitadores eletrostáticos e succionam os gases da fornalha, direcionando-os para a chaminé. O medidor de pressão da fornalha (PT) envia um sinal para o controlador (PIC), que compara o valor medido com o valor objetivo e atua nos variadores hidráulicos dos ventiladores de tiragem induzida, variando suas rotações. Há medições de pressão dos gases na entrada e saída dos superaquecedores (entrada do banco de tubos), na saída do banco de tubos (entrada dos economizadores) e na saída dos economizadores. A diferença de pressão dos gases entre a entrada e a saída do banco de tubos gera a indicação da pressão diferencial dos gases no banco de tubos (PDTB) e a diferença de pressão dos gases entre a fornalha e a saída dos economizadores gera a



indicação da pressão diferencial da caldeira (PDTC). A Figura 2.13 apresenta o desenho esquemático do fluxo dos gases na fornalha da caldeira.




Figura 2.13: Fluxo de gases na fornalha da caldeira.  
(Fonte: TAPPI, 2001)

A Figura 2.14 apresenta o fluxo dos gases nos tubos no superaquecedor.




Figura 2.14: Desenho esquemático do fluxo de gases no superaquecedor.  
(Fonte: TAPPI, 2001)



A Figura 2.15 apresenta o fluxo dos gases no economizador.




Figura 2.15: Desenho esquemático do fluxo de gases no economizador.

(Fonte: TAPPI, 2001)

A Figura 2.16 apresenta o perfil de temperatura dos gases dentro de uma caldeira de recuperação.




Figura 2.16: Desenho esquemático do perfil de temperatura dos gases na caldeira.



### 2.3.5.3. Sistema de Resfriamento dos Fundidos

Os fundidos precisam ser retirados da caldeira para a recuperação das substâncias químicas. Na parte inferior da fornalha, na parede traseira, há quatro aberturas para o escoamento dos fundidos para as bicas. As bicas são calhas externas à caldeira, resfriadas em contato indireto por água alcalina, que direcionam os fundidos para o tanque de dissolução. A Figura 2.17 mostra o desenho esquemático de uma bica de fundidos.




Figura 2.17: Desenho esquemático de uma bica de fundidos.

A Figura 2.18 apresenta uma bica de fundidos em operação.



Figura 2.18: Bica de fundidos.



A Figura 2.19 apresenta o fluxograma do sistema de resfriamento das bicas de fundidos.

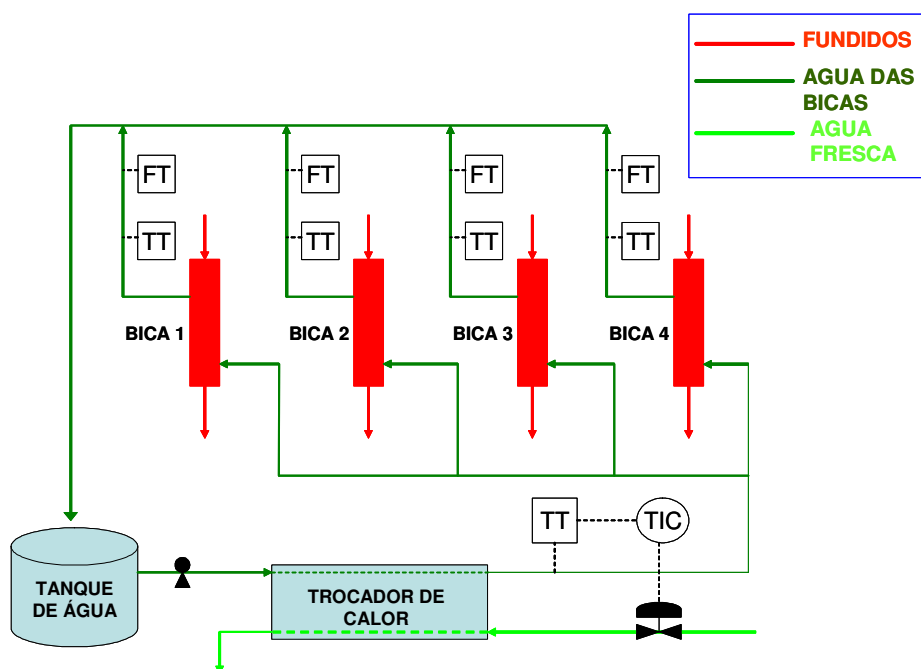


Figura 2.19: Fluxograma do sistema de resfriamento das bicas de fundidos.

O sistema de água alcalina para resfriamento das bicas é fechado. A água alcalina armazenada no tanque é bombeada passando por um trocador de calor para resfriamento. O fluido frio é água industrial. Na saída do trocador, há um medidor de temperatura (TT) da água alcalina e um controlador automático de temperatura (TIC) que atua na regulação da válvula de controle da água industrial. O controle automático de temperatura objetiva manter a temperatura da água alcalina de forma estável e num ponto ótimo. A utilização de água a temperatura ambiente (fria) aumenta o risco de trincas no material das bicas. Vazamentos de água nessa região são considerados críticos em termos de segurança, devido aos riscos de explosão pelas reações de contato entre fundidos e água. A água alcalina na saída das bicas possui medição individual de temperatura (TT) e vazão (FT), retornando ao tanque.



### 2.3.5.4. Sistema de Água e Vapor

A Figura 2.20 apresenta o fluxo de água e vapor da caldeira de recuperação química.

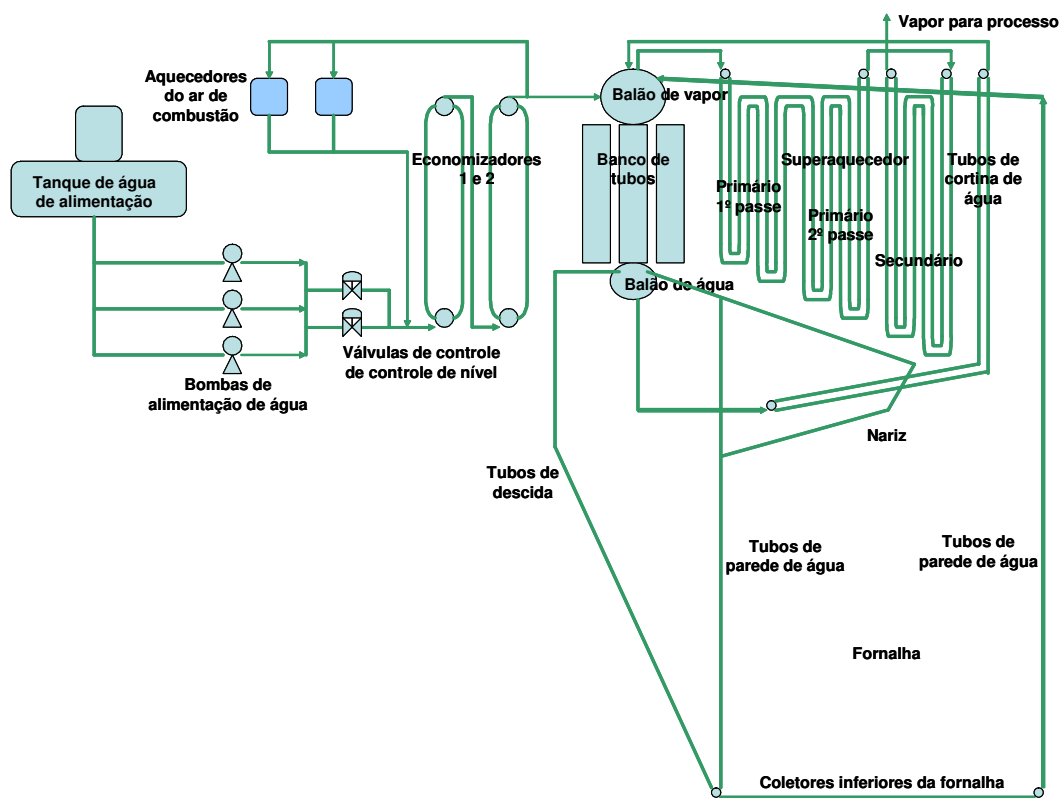


Figura 2.20: Fluxograma de água e vapor.

Água de alimentação é bombeada do tanque de água de alimentação para a caldeira. Após as bombas, há duas válvulas automáticas para o controle do nível do balão de vapor, mostrado adiante. A água passa primeiramente pelo economizador, um trocador de calor tubular que antecede o tubulão de vapor, pelo circuito de água. A água de alimentação passa dentro dos tubos aumentando a sua temperatura e aproveitando o calor dos gases de combustão na saída da caldeira. O economizador possui esse nome porque tem a função de reduzir a quantidade de combustível para a geração de vapor. Nesta caldeira, há dois painéis de economizadores, denominados economizadores 1 e 2. Após o economizador, a água segue para o balão de vapor. Essa caldeira possui dois balões, balão de vapor e balão de água.



Na saída do economizador há uma saída de água que segue para aquecer o ar primário e o ar secundário, por meio de contato indireto. Após o aquecimento, a água retorna para a entrada do economizador. A Figura 2.21 apresenta a malha de controle da temperatura do ar primário e secundário.

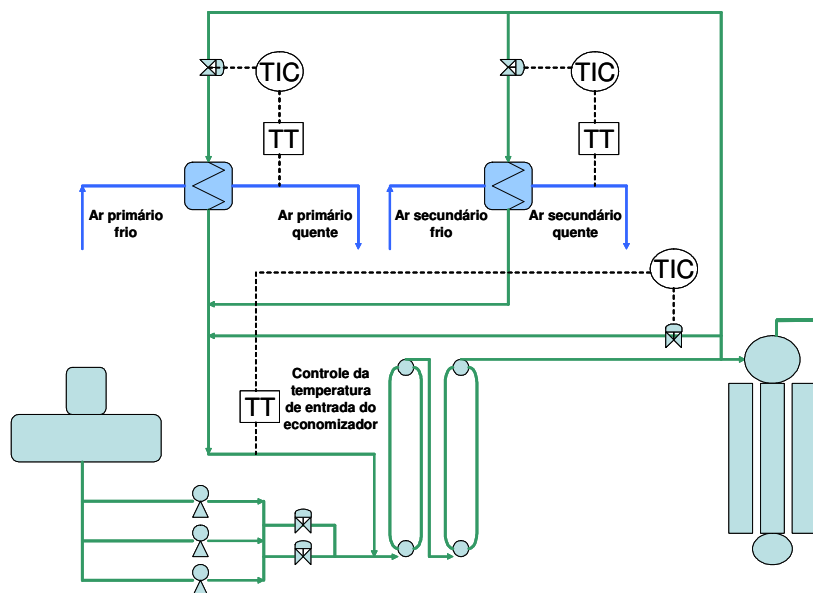


Figura 2.21: Fluxograma de controle automático das temperaturas do ar primário e secundário.

A temperatura do ar primário, após o aquecedor é medida e controlada automaticamente (TIC) por meio da regulação da válvula automática de água. Para o ar secundário, ocorre da mesma forma. O ar terciário não sofre aquecimento.

A caldeira é do tipo de caldeira com circulação natural, ou seja, a circulação da água pela caldeira não é realizada por meio de bombeamento. Uma das circulações de água na caldeira é entre o balão de vapor e o balão de água, através do banco de tubos, conjunto de tubos que interligam os dois balões. A segunda circulação de água é por meio dos tubos de descida que saem do balão de água e vão para os coletores inferiores da fornalha. Os tubos saem destes coletores para formar os tubos de parede de água da fornalha. O fluxo da mistura água e vapor é ascendente e retorna ao balão de vapor. A terceira circulação de água é do balão de água para o coletor dos tubos da cortina de água, descarregando no balão de vapor. Os tubos da cortina de água servem para proteger o superaquecedor das altas temperaturas dos gases.



O vapor que sai do balão de vapor é saturado. Ele alimenta o superaquecedor, trocador de calor que tem como função transformar o vapor saturado em vapor superaquecido. O vapor percorre o superaquecedor primário, em fluxo contracorrente em relação aos gases. Após, percorre o superaquecedor secundário em sentido co-corrente. O vapor superaquecido sai da caldeira para o processo.

O controle automático do nível (LIC) do balão de vapor é realizado pelas medições do nível (LT) do balão, da vazão (FT) de vapor de saída da caldeira e da vazão (FT) de água de alimentação para a caldeira. O controlador (LIC) manipula a regulação das válvulas automáticas de alimentação de água para manter o nível dentro do valor objetivo. A Figura 2.22 apresenta o fluxograma de controle do nível do balão.




Figura 2.22: Fluxograma de controle automático do nível do balão de vapor.

O controle da temperatura do vapor superaquecido é realizado a partir do dessuperaquecedor, pela injeção de condensado no vapor. A Figura 2.23 apresenta o fluxograma de controle de temperatura.



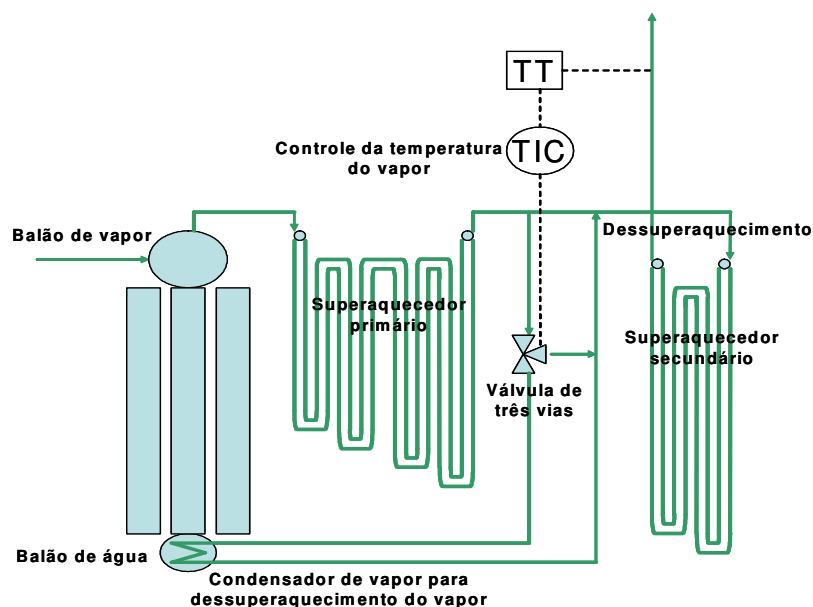


Figura 2.23: Fluxograma do controle automático de temperatura do vapor.

O condensado é gerado no condensador, localizado internamente ao balão de água. O vapor superaquecido na saída do superaquecedor primário alimenta o condensador e, depois de sofrer condensação, é injetado no vapor superaquecido. Há uma válvula de três vias que é regulada pelo controlador automático de temperatura do vapor superaquecido.

A Tabela 2.2 mostra a lista das principais malhas de controle da caldeira. Para cada malha de controle são mostradas as variáveis controlada e manipulada e a existência sensores de medição redundantes. A escolha das malhas de controle a serem estudadas foi baseada na não existência de redundância física nos sensores de medição das variáveis controladas. As malhas escolhidas foram: vazão de ar primário, vazão de ar secundário, vazão de ar terciário, pressão da fornalha e temperatura da água de resfriamento das bicas de fundidos. A malha de vazão de ar total pode ser monitorada pelas malhas de ar primário, secundário e terciário, somadas.



Tabela 2.2: Listagem das malhas da caldeira de recuperação química.

Malha de controle	Variável manipulada	Há medição redundante?
Vazão de ar primário	Posição da guilhotina do ventilador de ar primário	Não
Vazão de ar secundário	Posição da guilhotina do ventilador de ar secundário	Não
Vazão de ar terciário	Posição da guilhotina do ventilador de ar terciário	Não
Vazão de ar total	Posição da guilhotina dos ventiladores de ar primário, secundário e terciário	Não
Temperatura do ar primário	Posição da válvula de água quente para o aquecedor de ar primário	Sim
Temperatura do ar secundário	Posição da válvula de água quente para o aquecedor de ar secundário	Sim
Pressão da fornalha	Rotação dos ventiladores de tiragem induzida	Não
Temperatura da água de resfriamento das bicas	Posição da válvula de água industrial para trocador de calor da água de resfriamento das bicas	Não
Nível de água no balão	Posição da válvula de água de alimentação para a caldeira	Sim
Vazão de licor para queima	Posição da válvula de licor para queima	Sim
Pressão do licor para queima	Posição da válvula de licor para queima	Sim
Temperatura do vapor	Posição das válvulas de passagem de vapor superaquecido para condensador no balão inferior	Sim



### 3. METODOLOGIA

A proposta deste trabalho é desenvolver um método para detecção de defeitos, via redes neurais artificiais, baseado no conceito de geração de resíduos, e aplicá-lo em uma caldeira de uma recuperação química. Uma MLP é utilizada para reproduzir o comportamento quase-estático das malhas de controle. A condição quase-estática é assumida porque o objetivo é detectar os defeitos incipientes. Não é o foco do trabalho o tratamento dos defeitos que se apresentam de forma abrupta. O principal motivo para se utilizar uma MLP para descrever o comportamento deste processo é a dificuldade para construção de um modelo fenomenológico. O comportamento de uma caldeira de recuperação química é altamente complexo, conforme apresentado no capítulo 4. A RNA é treinada com dados coletados do processo produtivo na ausência de defeitos. Ela é obtida empregando-se o programa Statistica Neural Networks, versão 4, conforme apresentado no apêndice A. O esquema de treinamento da RNA de predição é apresentado na Figura 3.1:

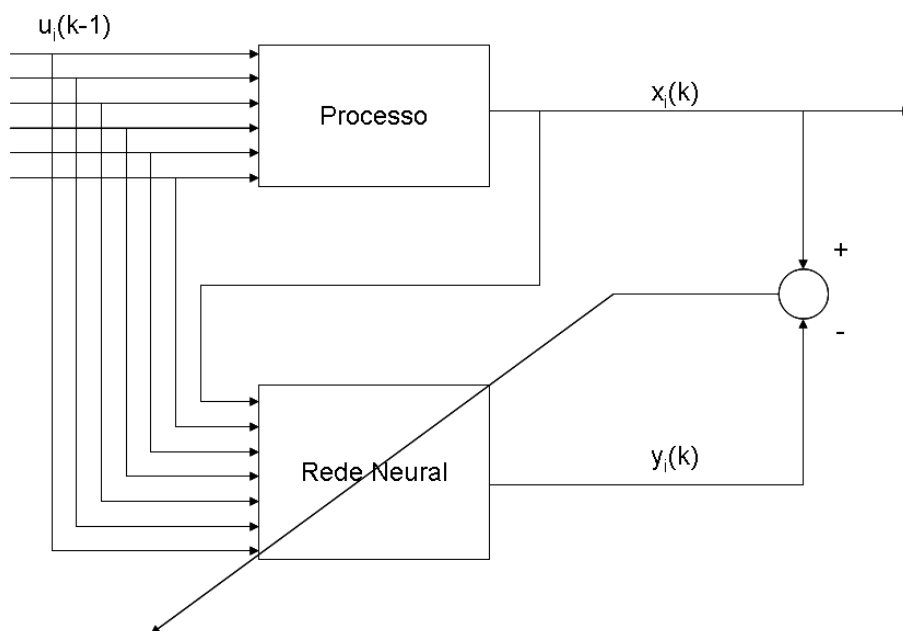


Figura 3.1: Esquema simplificado de treinamento da RNA de predição.

Após o treinamento, a rede de predição é utilizada para monitoramento do processo. A comparação entre os valores medidos do processo produtivo com os valores inferidos pela MLP dá origem aos resíduos, calculados da seguinte forma:



$$r_i(k) = x_i(k) - y_i(k), \quad i = 1, \dots, n \quad (3.1)$$

em que,  $x_i(k)$  são as medições e  $y_i(k)$  são os valores inferidos. O esquema de geração de resíduos é apresentado na Figura 3.2.

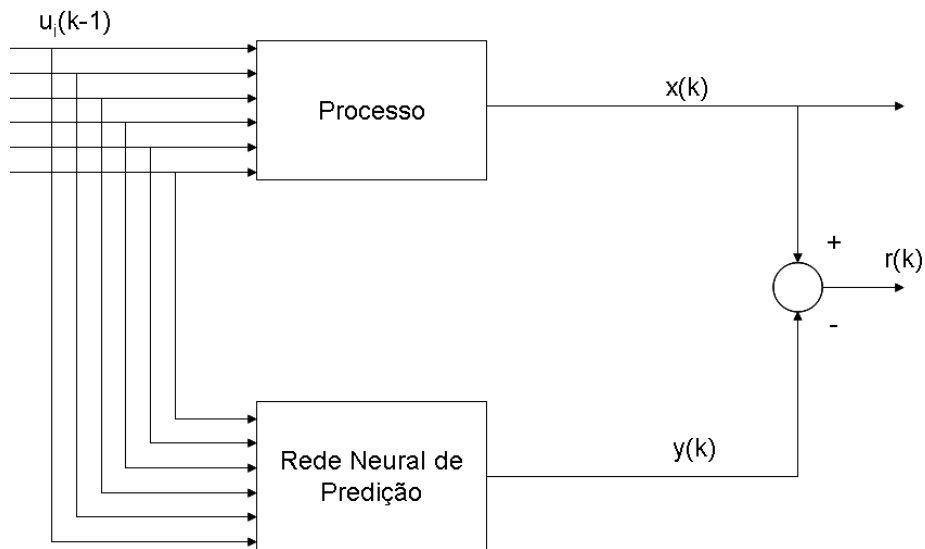


Figura 3.2: Esquema simplificado de geração de resíduos.

Na ausência de defeitos, os resíduos são oriundos dos ruídos e dos erros de modelagem (RUZ-HERNANDEZ, 2006). Se os ruídos e os erros de modelagem forem significativos, os defeitos podem ser encobertos ocasionando erros na detecção. Para minimizar os erros de modelagem, foram utilizados dados médios do processo para o treinamento das RNA de predição. Como os erros de modelagem e os ruídos de medida são inevitáveis em sistemas reais, utiliza-se outra rede neural para construir faixas de detecção variáveis. Desta forma, se os erros de modelagem são maiores em determinados pontos de operação, a RNA conseguirá abstrair essas características e, assim, alarmes falsos não serão disparados (TINOS, 1999). A RNA utilizada para a função de análise dos resíduos foi uma MLP de classificação, conforme apresentado no capítulo 3. As entradas desta rede foram o resíduo e as variáveis de entrada da RNA de predição, e o seu treinamento foi realizado com dados na ausência e na presença de defeitos, gerados pela inclusão de erros nos sinais das variáveis de processo. Esta estratégia é utilizada pela dificuldade de inserção de defeitos nos sensores deste



processo crítico, durante a sua operação normal. A estratégia de treinamento da RNA de classificação é apresentada na Figura 3.3. Após o treinamento, as duas redes são utilizadas para monitoramento do processo. A Figura 3.4 apresenta o esquema de operação do método de detecção de defeitos.

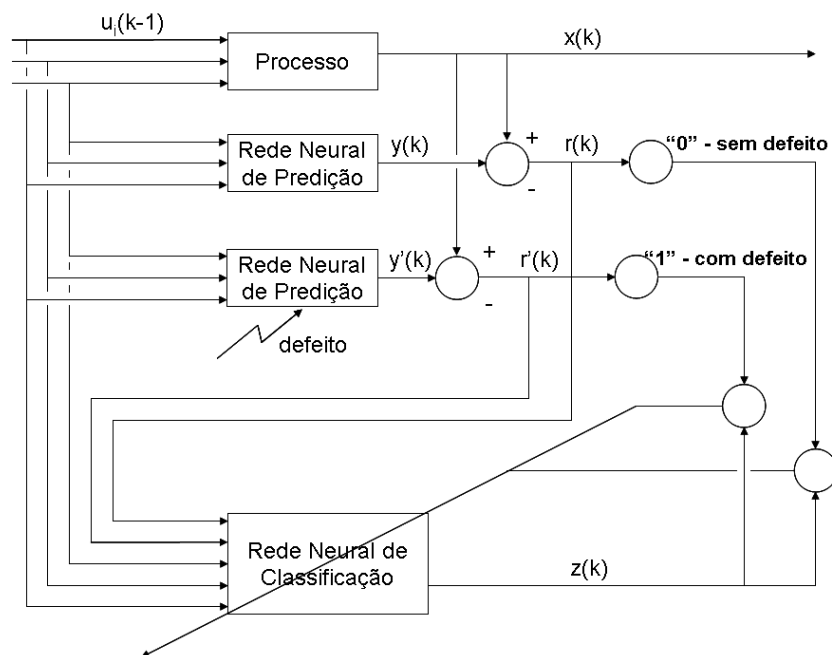


Figura 3.3: Esquema simplificado de treinamento da RNA de classificação.

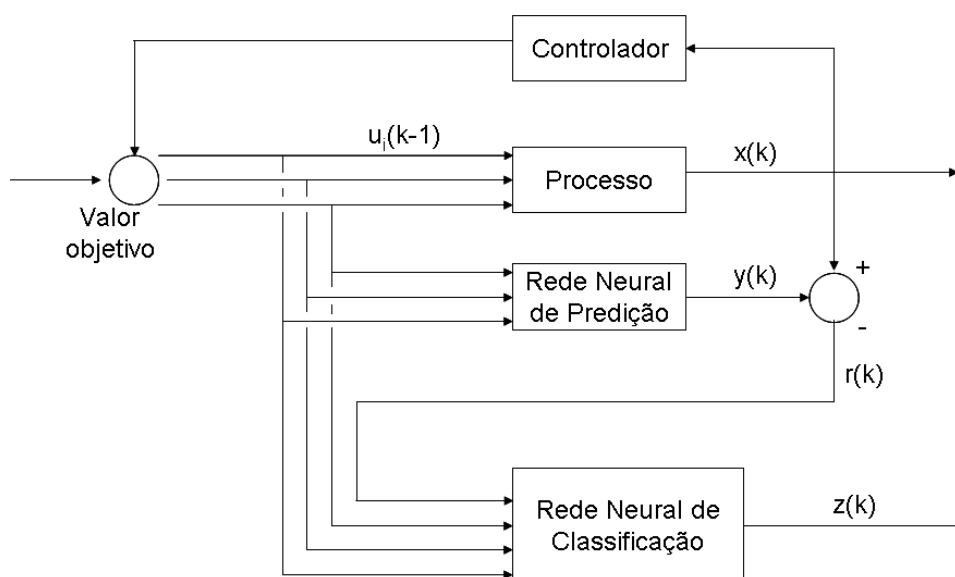


Figura 3.4: Esquema simplificado de operação do método de detecção de defeitos.



### 3.1. Procedimento para Treinamento

1. Define-se a malha de controle a ser monitorada.
2. Faz-se uma pré-definição das variáveis de processo correlacionadas com esta malha, de acordo com conhecimento especialista.
3. Coletam-se os dados médios de períodos de trinta minutos destas variáveis, durante a operação normal do processo produtivo (na ausência de defeitos). A coleta de dados é realizada utilizando-se o programa Plant Information (PI).

Obs.: no início do desenvolvimento do trabalho foram testadas amostragens de dados pontuais e médios, em vários períodos de tempo. Para a detecção de defeitos incipientes, os dados médios de trinta minutos se mostraram como a melhor opção entre a velocidade do método (habilidade do método para detectar defeitos com atraso relativamente pequeno, em relação à sua origem) e a precisão do modelo de predição, pela minimização de ruídos nos dados médios.

4. Realiza-se a limpeza dos dados, eliminando-se períodos em que o PI estava fora de operação, períodos de parada e curvas de reinício do equipamento.
5. Efetua-se o treinamento da rede neural de predição por meio do programa Statistica Neural Networks. Este treinamento é processado de acordo com as definições: (a) treinamento avançado, (b) tipo de problema convencional, (c) saída do controlador como variável de saída, (d) definição automática das variáveis de entrada, (e) divisão dos dados de forma aleatória com cinquenta por cento (50%) para treinamento, vinte e cinco (25%) para verificação e vinte e cinco (25%) para validação, (f) rede MLP, (g) complexidade da rede definida automaticamente, (h) tempo de treinamento longo.
6. Determinam-se os resultados estatísticos: coeficiente de correlação; análise de sensibilidade; resíduo médio; desvio padrão do resíduo; resíduo médio absoluto; desvio padrão do resíduo absoluto e o intervalo considerando o resíduo médio absoluto  $\pm$  três desvios padrão do resíduo absoluto.
7. Analisam-se os resultados.

Se a rede não apresentar resultados satisfatórios, aumenta-se a base de dados no passo 3 e repetem-se os passos 4, 5, 6 e 7. Caso contrário continua-se no passo 8.

8. Coleta-se nova base de dados, conforme passo 3 acima.
9. Realiza-se a limpeza dos dados, conforme passo 4.



10. Realiza-se a programação da RNA de predição no programa Excel, para realização da segunda validação (etapa 11) e a inclusão de erros nas variáveis (etapa 14).

11. Faz-se uma segunda validação do modelo com a nova base de dados do passo 8.

Obs.: a etapa de segunda validação do modelo de predição objetiva aumentar a sua robustez.

12. Determinam-se os resultados estatísticos, conforme o passo 6.

13. Comparam-se os resultados com os obtidos no passo 6.

Se os resultados do passo 12 não forem satisfatórios em relação ao passo 6, aumenta-se a base de dados de treinamento no passo 3 e repetem-se todos os passos subsequentes. Caso contrário, continua-se no passo 14.

14. Inserem-se erros nas variáveis de forma que o resíduo apresente intervalo igual ou maior que o intervalo determinado nos passo 12 ou 6, o que for maior dos dois passos.

15. Efetua-se o treinamento da rede neural de classificação por meio do programa Statistica Neural Networks com as bases de dados sem defeitos (passos 6 e 8) e com defeitos (passo 14). As variáveis de entrada da rede são o resíduo e as mesmas variáveis de entrada da rede neural de predição, do passo 6. O treinamento é processado de acordo com as definições: (a) treinamento avançado, (b) tipo de problema convencional, (c) saída do controlador como “verdadeiro” (que significa dados sem defeitos) ou “falso” (que significa dados defeituosos), (d) definição automática das variáveis de entrada, (e) divisão dos dados de forma aleatória com cinquenta por cento (50%) para treinamento, vinte e cinco (25%) para verificação e vinte e cinco (25%) para validação, (f) limites de confiabilidade determinados automaticamente, (g) rede MLP, (h) complexidade da rede definida automaticamente, (i) tempo de treinamento longo.

16. Determinam-se os resultados estatísticos: taxa de classificação correta; taxa de classificação falsa e análise de sensibilidade.

Se as taxas de classificação correta e falsa não forem satisfatórias, aumenta-se o erro inserido no passo 14 e repetem-se os passos seguintes. O fluxograma esquemático do procedimento para treinamento é apresentado na Figura 3.5.



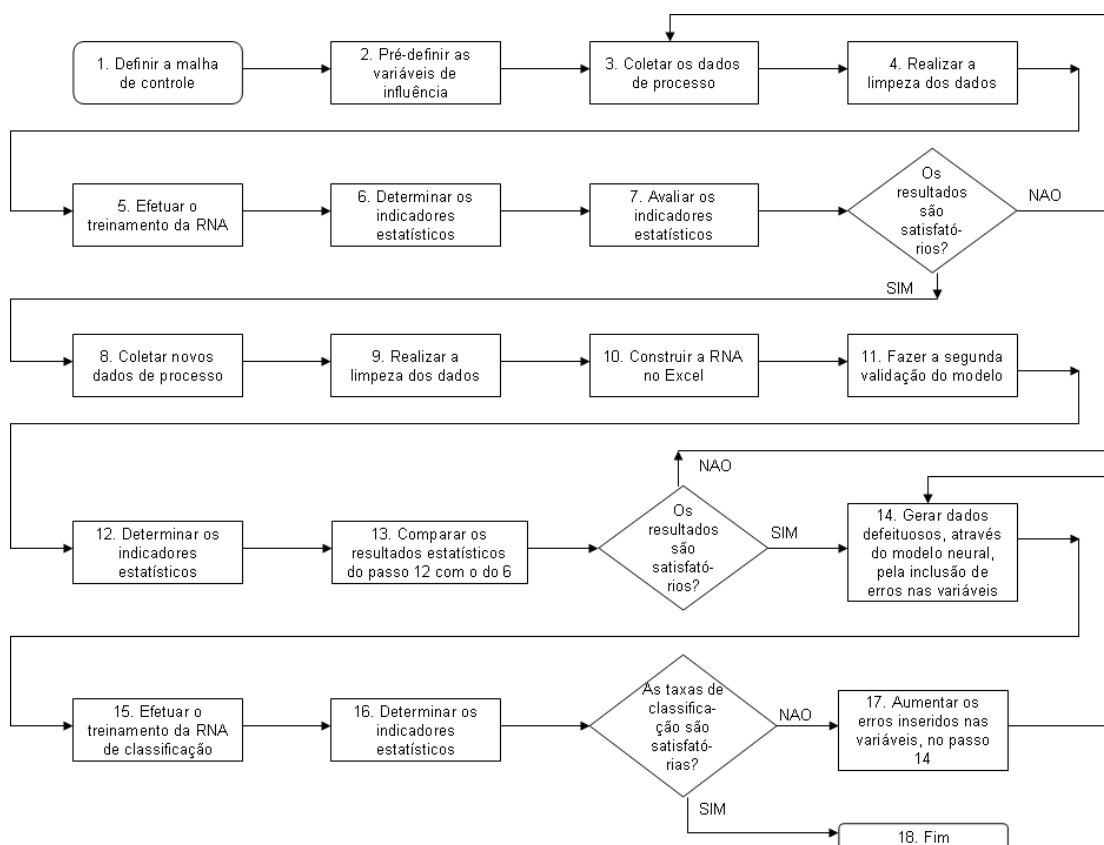


Figura 3.5: Fluxograma esquemático simplificado do procedimento para treinamento.

### 3.2. Procedimento para Operação

1. Coletam-se as variáveis de processo em tempo real para uma planilha do programa Excel, por meio do PI.
2. As variáveis sofrem pré-teste baseado em três requisitos: teste do valor numérico, teste de checagem de limites (de acordo com o limite máximo e o mínimo que a RNA foi treinada) e teste de congelamento de sinais (sinais iguais no tempo  $t$  e  $t + \Delta t$ ) indicam que pode haver defeito). O resultado deste teste é informado ao usuário.
3. As variáveis sofrem pré-processamento no programa Excel.
4. Os valores das variáveis de entrada são apresentados à entrada da rede de predição, que tem como estimativa a variável de saída.
5. A saída da rede é comparada com a variável medida no processo no mesmo instante de tempo, gerando o resíduo.
6. O resíduo é apresentado à entrada da rede de classificação.
7. A rede de classificação identifica a existência ou não de um defeito.



8. Incrementa-se o tempo  $t$  e retorna-se ao passo 1.



## **4. RESULTADOS E DISCUSSÃO**

A metodologia foi aplicada em cinco malhas de controle da caldeira de recuperação química: controles das vazões do ar primário; secundário e terciário; controle da temperatura da água de resfriamento das bicas de fundidos e controle da pressão da fornalha.

### **4.1. Malha de Controle da Vazão de Ar Primário**

As variáveis de influência pré-definidas para a modelagem desta malha foram: vazão de ar primário (VARP); saída do controlador de ar primário (OVARP); percentagem da corrente do motor do ventilador de ar primário em relação à corrente nominal (CARP); temperatura do ar primário na entrada da caldeira (TARP); pressão do ar primário na entrada da caldeira (PARP) e pressão da fornalha (PFOR).

As Figuras 4.1 (a, b, c, d, e, f) mostram os sinais das variáveis apresentadas a MLP. Eles são valores médios, de um período de trinta minutos, das variáveis de processo. Os dados foram coletados durante operação normal do processo produtivo, na ausência de defeitos, com auxílio do PI. Para a construção da MLP de predição foram utilizados 11.199 padrões, que correspondem a 233 dias de operação.






Figura 4.1 a: Vazão de ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.




Figura 4.1 b: Pressão de ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.



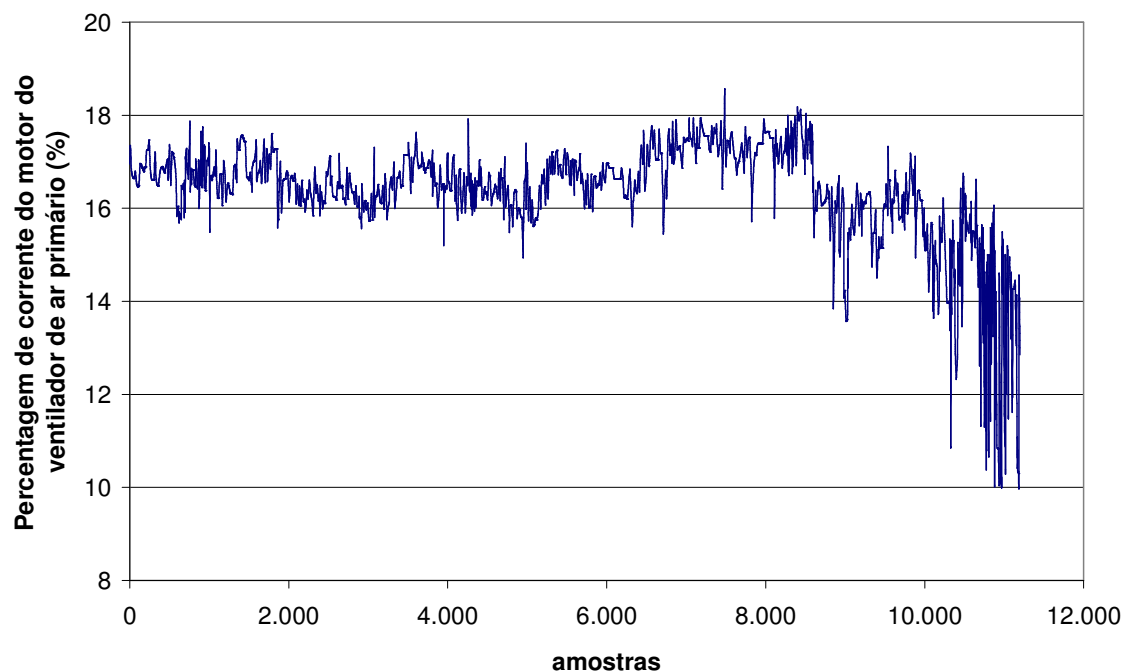


Figura 4.1 c: Percentagem de corrente do motor do ventilador de ar primário, em relação à corrente nominal, para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.




Figura 4.1 d: Temperatura do ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.






Figura 4.1 e: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.




Figura 4.1 f: Saída do controlador de vazão do ar primário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.



Tabela 4.1: Características dos dados utilizados para o treinamento da MLP de predição da malha de controle da vazão do ar primário.

Variáveis	Etapa de treinamento, verificação e validação			
	Média	Desvio padrão	Valor máximo	Valor mínimo
VARP (Nm <sup>3</sup> /h)	101.700	4732	112.253	74.884
CARP (%)	16,39	1,03	18,56	10,00
PARP (mmCA)	96,43	13,33	190,87	39,61
TARP (°C)	158,77	3,40	174,70	146,07
PFOR (mmCA)	4,01	1,48	14,25	-10,75
OVARP (%)	24,57	4,73	40,10	13,38

A Tabela 4.2 apresenta as características da MLP de predição do sistema de ar primário e a Figura 4.2 mostra a sua estrutura simplificada.

Tabela 4.2: Características da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.

Número de unidades na primeira camada	5
Número de unidades na camada intermediária	3
Número de unidades na última camada	1
Variáveis de entrada selecionadas	VARP, CARP, PARP, TARP e PFOR
Variável de saída	OVARP




Figura 4.2: Estrutura simplificada da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.

A Figura 4.3 mostra a comparação entre os sinais medidos no processo para OVARP e os sinais de saída da MLP, para as etapas de treinamento, verificação e validação. A Figura 4.4 apresenta os resíduos destas etapas.






Figura 4.3: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar primário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar primário.




Figura 4.4: Resíduos das saídas do controlador de vazão do ar primário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de vazão do ar primário.

A Tabela 4.3 apresenta os resultados estatísticos da MLP de predição. O resíduo médio, na ausência de defeitos, é de  $-0,07\%$ , com desvio padrão de  $3,33\%$ . Considerando o intervalo compreendido entre a média do resíduo  $\pm$  três desvios padrão têm-se,  $[-10,1$  a  $9,9]$ .



Tabela 4.3: Resultados estatísticos da MLP de modelo de predição da malha de vazão do ar primário, na ausência de defeitos.

Variáveis	Etapas de treinamento, verificação e validação
Média do resíduo	-0,07 %
Desvio padrão do resíduo	3,33 %
Intervalo do resíduo médio $\pm 3$ desvios padrão	[-10,1 a 9,9] %
Média do resíduo absoluto	2,42 %
Coeficientes de correlação do modelo: treinamento/verificação/validação	0,712 / 0,702 / 0,715, respectivamente

Uma segunda validação foi realizada na MLP. Foram coletados 4.035 novos padrões de operação. As Figuras 4.5 (a, b, c, d, e, f) mostram estes sinais.




Figura 4.5 a: Vazão do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.






Figura 4.5 b: Pressão do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.




Figura 4.5 c: Percentual de corrente do motor do ventilador de ar primário, em relação à corrente nominal, para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.






Figura 4.5 d: Temperatura do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.




Figura 4.5 e: Pressão da fornalha para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.






Figura 4.5 f: Saída do controlador de vazão do ar primário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário, livre de defeitos.

A Figura 4.6 apresenta a comparação entre os sinais reais (medidos no processo, na ausência de defeitos) com os sinais inferidos pela MLP, das saídas do controlador de vazão do ar primário na etapa de segunda validação. A Figura 4.7 apresenta os resíduos nesta mesma etapa.






Figura 4.6: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar primário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da vazão do ar primário.




Figura 4.7: Resíduos das saídas do controlador de vazão do ar primário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle de vazão do ar primário.



A Tabela 4.4 apresenta os resultados estatísticos da MLP de predição para a etapa de segunda validação e compara estes resultados com os das etapas de treinamento, verificação e validação. Observa-se que o intervalo de variação do resíduo é ligeiramente maior na etapa de segunda validação.

Tabela 4.4: Comparação dos resultados estatísticos da MLP de predição da malha de vazão do ar primário, entre as etapas de segunda validação e treinamento, verificação e validação.

Variáveis	Etapa da segunda validação	Etapas de treinamento, verificação e validação
Média do resíduo	0,38 %	-0,07%
Desvio padrão do resíduo	4,38 %	3,33%
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-12,8 a 13,5] %	[-10,1 a 9,9] %

A Figura 4.8 apresenta os sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar primário, nas duas etapas, treinamento, verificação e validação e segunda validação. A Figura 4.9 apresenta os resíduos nas duas etapas.




Figura 4.8: Sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar primário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da vazão do ar primário.






Figura 4.9: Resíduos das saídas do controlador de vazão do ar primário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de vazão do ar primário. A faixa representa o intervalo compreendido entre a média  $\pm 3$  desvios padrão.

O treinamento da MLP de classificação de resíduos foi realizado com dados sem defeitos e dados defeituosos. Estes foram gerados por meio da MLP de predição, com a inserção de erros nos sinais das variáveis. Para minimizar a taxa de alarmes falsos na MLP de classificação, foram inseridos erros para resíduos maiores que o intervalo de  $[-12,8 \text{ a } 13,5]$  obtido na etapa de segunda validação.

A Tabela 4.5 mostra as características da MLP de classificação de resíduos e a Figura 4.10, sua estrutura simplificada.

Tabela 4.5: Características da MLP de classificação dos resíduos da malha de controle da vazão do ar primário.

Número de unidades na primeira camada	5
Número de unidades na camada intermediária	5
Número de unidades na última camada	1
Variáveis de entrada selecionadas	VARP, CARP, TARP, PFOR, e RESIDUO
Variável de saída	CLAS (“VERDADEIRO” ou “FALSO”)






Figura 4.10: Estrutura simplificada da MLP de classificação dos resíduos da malha de controle da vazão do ar primário.

O desempenho da MLP de classificação, nas etapas de treinamento, verificação e validação, foi determinado pela taxa de classificação correta dos resíduos. A Tabela 4.6 mostra que a MLP conseguiu classificar corretamente 98,6% dos dados do treinamento, 98,5% dos dados da verificação e 98,5% dos dados da validação.

Tabela 4.6: Desempenho da MLP de classificação dos resíduos da malha de controle da vazão do ar primário.

	Etapas					
	Treinamento		Verificação		Validação	
	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos
Dados totais	7808	15043	3741	7684	3685	7741
Dados com classificação correta	7695	14834	3688	7568	3629	7622
Dados com classificação errada	113	209	53	116	56	119
% de dados com classificação correta	98,6		98,5		98,5	
% de dados com classificação errada	1,4		1,5		1,5	

As duas redes neurais foram configuradas em programa Excel para o monitoramento do sistema de ar primário. A Figura 4.11 apresenta a tela principal do sistema de detecção.






Figura 4.11: Tela do sistema de detecção de defeitos do sistema de ar primário da caldeira de recuperação química.

O método foi utilizado para monitoramento do processo durante 88 dias. Neste período, a taxa de alarmes falsos foi de 5%.

A taxa de detecção do método foi determinada pela inserção de erros, de 1% a 20%, nos sinais de saída do controlador de vazão do ar primário. A Figura 4.12 mostra a taxa de detecção do método versus a magnitude dos erros inseridos. Observa-se que o método foi capaz de detectar 51% do total de defeitos para erros de 8% e 96%, para erros de 13%.




Figura 4.12: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de vazão do ar primário.



## 4.2. Malha de Controle da Vazão de Ar Secundário

As variáveis de influência pré-definidas para a modelagem desta malha foram: vazão de ar secundário (VARS); saída do controlador de ar secundário (OVARs); percentagem da corrente do motor do ventilador de ar secundário em relação à corrente nominal (CARS) e pressão do ar secundário na entrada da caldeira (PARS).

As Figuras 4.13 (a, b, c, d) mostram os sinais das variáveis apresentadas a MLP. Eles são valores médios, de um período de trinta minutos, das variáveis de processo. Os dados foram coletados durante operação normal do processo produtivo, na ausência de defeitos. Para a construção da MLP de predição, foram utilizados 16.662 padrões, que correspondem a 347 dias de operação.




Figura 4.13 a: Vazão de ar secundário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.






Figura 4.13 b: Pressão de ar secundário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.




Figura 4.13 c: Percentagem de corrente do motor do ventilador de ar secundário, em relação à corrente nominal, para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.






Figura 4.13 d: Saída do controlador de vazão do ar secundário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.

Tabela 4.7: Características dos dados utilizados para o treinamento da MLP de predição da malha de controle da vazão do ar secundário.

Variáveis	Etapa de treinamento, verificação e validação			
	Média	Desvio padrão	Valor máximo	Valor mínimo
VARs (Nm <sup>3</sup> /h)	121,265	4,797	134,224	100,000
CARS (%)	23,43	1,23	27,05	18,09
PARs (mmCA)	323,89	27,47	424,73	181,44
OVARS (%)	47,01	7,81	83,68	19,21

A Tabela 4.8 apresenta as características da MLP de predição do sistema de ar secundário e a Figura 4.14 mostra a sua estrutura simplificada.

Tabela 4.8: Características da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.

Número de unidades na primeira camada	3
Número de unidades na camada intermediária	2
Número de unidades na última camada	1
Variáveis de entrada selecionadas	VARs, CARS, PARs
Variável de saída	OVARS






Figura 4.14: Estrutura simplificada da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.

A Figura 4.15 mostra a comparação entre os sinais medidos no processo e os sinais de saída da MLP, para as etapas de treinamento, verificação e validação. A Figura 4.16 apresenta os resíduos destas etapas.




Figura 4.15: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar secundário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar secundário.






Figura 4.16: Resíduos das saídas do controlador de vazão do ar secundário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de vazão do ar secundário.

A Tabela 4.9 apresenta resultados estatísticos da MLP de predição. O resíduo médio, na ausência de defeitos, é de 0,01%, com desvio padrão de 3,43%. Considerando o intervalo compreendido entre a média do resíduo  $\pm$  três desvios padrão, têm-se [-10,3 a 10,3].

Tabela 4.9: Resultados estatísticos da MLP de modelo de predição da malha de vazão do ar secundário, na ausência de defeitos.

Variáveis	Etapas de treinamento, verificação e validação
Média do resíduo	0,01 %
Desvio padrão do resíduo	3,43 %
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-10,3 a 10,3] %
Média do resíduo absoluto	2,84 %
Coeficientes de correlação do modelo: treinamento/verificação/validação	0,895 / 0,902 / 0,900, respectivamente

Uma segunda validação foi realizada na MLP. Foram coletados 4.401 novos padrões de operação. As Figuras 4.17 (a, b, c, d) mostram estes sinais.






Figura 4.17 a: Vazão do ar secundário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.




Figura 4.17 b. Pressão do ar secundário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.






Figura 4.17 c: Percentual de corrente do motor do ventilador de ar secundário, em relação à corrente nominal, para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.




Figura 4.17 d: Saída do controlador de vazão do ar secundário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar secundário, livre de defeitos.

A Figura 4.18 apresenta a comparação entre os sinais reais (medidos no processo, na ausência de defeitos) com os sinais inferidos pela MLP, das saídas do



controlador de vazão do ar secundário na etapa de segunda validação. A Figura 4.19 apresenta os resíduos nesta mesma etapa.




Figura 4.18: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar secundário, livre de defeitos, da etapa de segunda validação da MLP de previsão da malha de controle da vazão do ar secundário.




Figura 4.19: Resíduos das saídas do controlador de vazão do ar secundário, livre de defeitos, da etapa de segunda validação da MLP de previsão da malha de controle de vazão do ar secundário.



A Tabela 4.10 apresenta os resultados estatísticos da MLP de predição para a etapa de segunda validação e compara estes resultados com os das etapas de treinamento, verificação e validação.

Tabela 4.10: Comparação dos resultados estatísticos da MLP de predição da malha de vazão do ar secundário, entre as etapas de segunda validação e treinamento, verificação e validação.

Variáveis	Etapa da segunda validação	Etapas de treinamento, verificação e validação
Média do resíduo	-1,13 %	0,01%
Desvio padrão do resíduo	3,67 %	3,43%
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-12,1 a 9,9] %	[-10,3 a 10,3] %

A Figura 4.20 apresenta os sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar secundário, nas duas etapas, treinamento, verificação e validação e segunda validação. A Figura 4.21 apresenta os resíduos nas duas etapas.




Figura 4.20: Sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar secundário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da vazão do ar secundário.






Figura 4.21: Resíduos das saídas do controlador de vazão do ar secundário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de vazão do ar secundário. A faixa representa o intervalo compreendido entre a média  $\pm 3$  desvios padrão.

O treinamento da MLP de classificação de resíduos foi realizado com dados sem defeitos e dados defeituosos. Estes foram gerados por meio da MLP de predição, com a inserção de erros nos sinais das variáveis. Para minimizar a taxa de alarmes falsos na MLP de classificação, foram inseridos erros para resíduos maiores que o intervalo de  $[-12,1 \text{ a } 10,3]$ .

A Tabela 4.11 mostra as características da MLP de classificação de resíduos e a Figura 4.22, sua estrutura simplificada.

Tabela 4.11: Características da MLP de classificação dos resíduos da malha de controle da vazão do ar secundário.

Número de unidades na primeira camada	4
Número de unidades na camada intermediária	16
Número de unidades na última camada	1
Variáveis de entrada selecionadas	VARS, CARS, PARS, RESIDUO
Variável de saída	CLAS






Figura 4.22: Estrutura simplificada da MLP de classificação dos resíduos da malha de controle da vazão do ar secundário.

O desempenho da MLP de classificação, nas etapas de treinamento, verificação e validação, foi determinado pela taxa de classificação correta dos resíduos. A Tabela 4.12 mostra que a MLP conseguiu classificar corretamente 97,1% dos dados do treinamento, 96,7% dos dados da verificação e 96,3% dos dados da validação.

Tabela 4.12: Desempenho da MLP de classificação dos resíduos da malha de controle da vazão do ar secundário

	Etapas					
	Treinamento		Verificação		Validação	
	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos
Dados totais	7959	44699	7701	18628	5403	20925
Dados com classificação correta	7687	43422	7475	17998	5223	20120
Dados com classificação errada	272	1277	226	630	180	805
% de dados com classificação correta	97,1		96,7		96,3	
% de dados com classificação errada	2,9		3,3		3,7	

As duas redes neurais foram configuradas em Excel para o monitoramento do sistema de ar secundário. A Figura 4.23 apresenta a tela principal do sistema de detecção.






Figura 4.23: Tela do sistema de detecção de defeitos do sistema de ar secundário da caldeira de recuperação química.

O método foi utilizado para monitoramento do processo durante 66 dias. Neste período, a taxa de alarmes falsos foi de 4,0 %.

A taxa de detecção do método foi determinada pela inserção de erros, de 1% a 20%, nos sinais de saída do controlador de vazão do ar secundário. A Figura 4.24 mostra a taxa de detecção do método versus a magnitude dos erros inseridos. Observa-se que o método foi capaz de detectar 89% do total de defeitos para erros de -16 % e 94% do total de defeitos para erros de 9 %.




Figura 4.24: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de vazão do ar secundário.



### 4.3. Malha de Controle da Vazão de Ar Terciário

As variáveis de influência pré-definidas para a modelagem desta malha foram: vazão de ar terciário (VART); saída do controlador de ar terciário (OVART); percentagem da corrente do motor do ventilador de ar terciário em relação à corrente nominal (CART) e pressão da fornalha (PFOR).

As Figuras 4.25 (a, b, c, d) mostram os sinais das variáveis apresentadas a MLP. Eles são valores médios, de um período de trinta minutos, das variáveis de processo. Os dados foram coletados durante operação normal do processo produtivo, na ausência de defeitos. Para a construção da MLP de predição, foram utilizados 13.944 padrões, que correspondem a 290 dias de operação.




Figura 4.25 a: Vazão de ar terciário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.






Figura 4.25 b: Percentagem de corrente do motor do ventilador de ar terciário, em relação à corrente nominal, para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.




Figura 4.25 c: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.






Figura 4.25 d: Saída do controlador de vazão do ar terciário para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.

Tabela 4.13: Características dos dados utilizados para o treinamento da MLP de predição da malha de controle da vazão do ar terciário.

Variáveis	Etapa de treinamento, verificação e teste			
	Média	Desvio padrão	Valor máximo	Valor mínimo
VART (Nm <sup>3</sup> /h)	80.629	3.278	88.478	63.886
CART (%)	21,78	0,82	24,29	16,89
PFOR (mmCA)	3,48	2,62	21,86	-8,69
OVART (%)	37,86	5,15	64,45	24,29

A Tabela 4.14 apresenta as características da MLP de predição do sistema de ar terciário e a Figura 4.26 mostra a sua estrutura simplificada.

Tabela 4.14: Características da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.

Número de unidades na primeira camada	3
Número de unidades na camada intermediária	16
Número de unidades na última camada	1
Variáveis de entrada selecionadas	VART, CART, PFOR
Variável de saída	OVART






Figura 4.26: Estrutura simplificada da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.

A Figura 4.27 mostra a comparação entre os sinais medidos no processo para OVART e os sinais de saída da MLP, para as etapas de treinamento, verificação e validação. A Figura 4.28 apresenta os resíduos destas etapas.




Figura 4.27: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar terciário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário.






Figura 4.28: Resíduos das saídas do controlador de vazão do ar terciário, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de vazão do ar terciário.

A Tabela 4.15 apresenta resultados estatísticos da MLP de predição. O resíduo médio, na ausência de defeitos, é de 0,25 %, com desvio padrão de 4,04%. Considerando o intervalo compreendido entre a média do resíduo  $\pm$  três desvios padrão, têm-se [-11,9 a 12,4].

Tabela 4.15: Resultados estatísticos da MLP de modelo de predição da malha de vazão do ar terciário, na ausência de defeitos.

Variáveis	Etapas de treinamento, verificação e validação
Média do resíduo	0,25 %
Desvio padrão do resíduo	4,04 %
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-11,9 a 12,4] %
Média do resíduo absoluto	2,98 %
Coefficientes de correlação do modelo: treinamento/verificação/validação	0,628 / 0,615 / 0,622, respectivamente

Uma segunda validação foi realizada na MLP. Foram coletados 4.150 novos padrões de operação. As Figuras 4.29 (a, b, c, d) mostram estes sinais.






Figura 4.29 a: Vazão do ar terciário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.




Figura 4.29 b: Percentual de corrente do motor do ventilador de ar terciário, em relação à corrente nominal, para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.






Figura 4.29 c: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.




Figura 4.29 d: Saída do controlador de vazão do ar terciário para a etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário, livre de defeitos.

A Figura 4.30 apresenta a comparação entre os sinais reais (medidos no processo, na ausência de defeitos) com os sinais inferidos pela MLP, das saídas do



controlador de vazão do ar terciário na etapa de segunda validação. A Figura 4.31 apresenta os resíduos nesta mesma etapa.




Figura 4.30: Sinais reais e inferidos pela MLP para a saída do controlador de vazão do ar terciário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da vazão do ar terciário.




Figura 4.31: Resíduos das saídas do controlador de vazão do ar terciário, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle de vazão do ar terciário.



A Tabela 4.16 apresenta os resultados estatísticos da MLP de predição para a etapa de segunda validação e compara estes resultados com os das etapas de treinamento, verificação e validação.

Tabela 4.16: Comparação dos resultados estatísticos da MLP de predição da malha de vazão do ar terciário, entre as etapas de segunda validação e treinamento, verificação e validação.

Variáveis	Etapas da segunda validação	Etapas de treinamento, verificação e validação
Média do resíduo	-0,59 %	0,25%
Desvio padrão do resíduo	3,22 %	4,04%
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-10,2 a 9,1] %	[-11,9 a 12,4] %

A Figura 4.32 apresenta os sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar terciário, nas duas etapas, treinamento, verificação e validação e segunda validação. A Figura 4.33 apresenta os resíduos nas duas etapas.




Figura 4.32: Sinais reais e inferidos pela MLP das saídas do controlador de vazão do ar terciário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da vazão do ar terciário.






Figura 4.33: Resíduos das saídas do controlador de vazão do ar terciário, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de vazão do ar terciário. A faixa representa o intervalo compreendido entre a média  $\pm 3$  desvios padrão.

O treinamento da MLP de classificação de resíduos foi realizado com dados sem defeitos e dados defeituosos. Estes foram gerados por meio da MLP de predição, com a inserção de erros nos sinais das variáveis. Para minimizar a taxa de alarmes falsos na MLP de classificação, foram inseridos erros para resíduos maiores que o intervalo de  $[-11,9 \text{ a } 12,4]$ .

A Tabela 4.17 mostra as características da MLP de classificação de resíduos e a Figura 4.34, sua estrutura simplificada.

Tabela 4.17: Características da MLP de classificação dos resíduos da malha de controle da vazão do ar terciário.

Número de unidades na primeira camada	4
Número de unidades na camada intermediária	19
Número de unidades na última camada	1
Variáveis de entrada selecionadas	VART, CART, PFOR, RESIDUO
Variável de saída	OVART






Figura 4.34: Estrutura simplificada da MLP de classificação dos resíduos da malha de controle da vazão do ar terciário.

O desempenho da MLP de classificação, nas etapas de treinamento, verificação e validação, foi determinado pela taxa de classificação correta dos resíduos. A Tabela 4.18 mostra que a MLP conseguiu classificar corretamente 96,6% dos dados do treinamento, 96,4% dos dados da verificação e 95,7% dos dados da validação.

Tabela 4.18: Desempenho da MLP de classificação dos resíduos da malha de controle da vazão do ar terciário.

	Etapas					
	Treinamento		Verificação		Validação	
	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos
Dados totais	7292	37943	5963	16654	4839	17779
Dados com classificação correta	7033	36669	5746	16060	4653	16996
Dados com classificação errada	259	1274	217	594	186	783
% de dados com classificação correta	96,6		96,4		95,7	
% de dados com classificação errada	3,4		3,6		4,3	

As duas redes neurais foram configuradas em programa Excel para o monitoramento do sistema de ar terciário. A Figura 4.35 apresenta a tela principal do sistema de detecção.



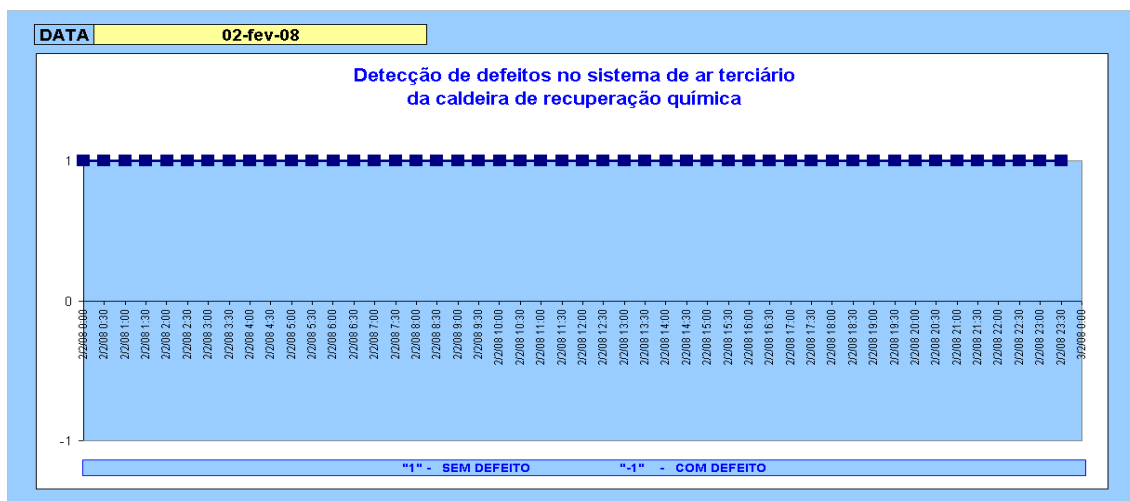


Figura 4.35: Tela do sistema de detecção de defeitos do sistema de ar terciário da caldeira de recuperação química.

O método foi utilizado para monitoramento do processo durante 65 dias. Neste período, a taxa de alarmes falsos foi de 0,2 %.

A taxa de detecção do método foi determinada pela inserção de erros, de 1% a 20%, nos sinais de saída do controlador de vazão do ar terciário. A Figura 4.36 mostra a taxa de detecção do método versus a magnitude dos erros inseridos. Observa-se que o método foi capaz de detectar 90% do total de defeitos para erros de -14 % e 82% do total de defeitos para erros de 19 %.




Figura 4.36: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de vazão do ar terciário.



#### 4.4. Malha de Controle da Temperatura da Água de Resfriamento das Bicas de Fundidos

As variáveis de influência pré-definidas para a modelagem desta malha foram: temperatura da água de resfriamento na entrada nas bicas (TAGEB); saída do controlador de temperatura água de resfriamento na entrada das bicas (OTAGB); temperatura média da água de resfriamento na saída das bicas (TMED) e diferença de temperatura da água de resfriamento entre a entrada e a saída das bicas (DIFE). De acordo com a Figura 2.19, é assumido que:

$$TMED = \left( \frac{TAGSB1 * VAGSB1 + TAGSB2 * VAGSB2 + TAGSB3 * VAGSB3 + TAGSB4 * VAGSB4}{VAGSB1 + VAGSB2 + VAGSB3 + VAGSB4} \right) \quad (4.1)$$

$$DIFE = TMED - TAGEB \quad (4.2)$$

em que,

TAGSB1, TAGSB2, TAGSB3 e TAGSB4: temperatura da água na saída das bicas 1, 2, 3 e 4, respectivamente.

VAGSB1, VAGSB2, VAGSB3 e VAGSB4: vazão da água na saída das bicas 1, 2, 3 e 4, respectivamente.

As Figuras 4.37 (a, b, c, d, e) mostram os sinais das variáveis apresentadas a MLP. Eles são valores médios, de um período de trinta minutos, das variáveis de processo. Os dados foram coletados durante operação normal do processo produtivo, na ausência de defeitos. Para a construção da MLP de predição, foram utilizados 10.098 padrões, que correspondem a 210 dias de operação.






Figura 4.37 a: Temperatura da água de resfriamento na entrada das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos.




Figura 4.37 b: Vazão total da água de resfriamento das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos.






Figura 4.37 c: Temperatura média da água de resfriamento na saída das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos.




Figura 4.37 d: Diferença de temperatura da água de resfriamento entre a entrada e a saída das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos.






Figura 4.37 e: Saída do controlador de temperatura da água de resfriamento das bicas para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos.

Tabela 4.19.: Características dos dados utilizados para o treinamento da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas.

Variável	Etapa de treinamento, verificação e validação			
	Média	Desvio padrão	Valor máximo	Valor mínimo
TAGEB (°C)	53,82	3,65	58,29	47,12
VTOT	46,41	2,51	47,99	35,02
TMED	56,65	3,87	64,38	48,98
DIFE	2,83	1,09	8,08	0,96
OTAGB	6,14	2,53	22,23	0,004

A Tabela 4.20 apresenta as características da MLP de predição do sistema de resfriamento das bicas de fundidos e a Figura 4.38 mostra a sua estrutura simplificada.

Tabela 4.20: Características das variáveis para treinamento da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas.

Número de unidades na primeira camada	4
Número de unidades na camada intermediária	28
Número de unidades na última camada	1
Variáveis de entrada selecionadas	TAGEB, VTOT, TMED, DIFE
Variável de saída	OTAGB






Figura 4.38: Estrutura simplificada da MLP de previsão da malha de controle da temperatura da água de resfriamento das bicas, livre de defeitos.

A Figura 4.39 mostra a comparação entre os sinais medidos no processo e os sinais de saída da MLP, para as etapas de treinamento, verificação e validação. A Figura 4.40 apresenta os resíduos destas etapas.






Figura 4.39: Sinais reais e inferidos pela MLP para a saída do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de temperatura de resfriamento da água das bicas.




Figura 4.40: Resíduos das saídas do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle de temperatura da água de resfriamento das bicas.



A Tabela 4.21 apresenta resultados estatísticos da MLP de predição. O resíduo médio, na ausência de defeitos, é de 0,02 %, com desvio padrão de 1,14%. Considerando o intervalo compreendido entre a média do resíduo  $\pm$  três desvios padrão têm-se, [-3,4 a 3,4].

Tabela 4.21: Resultados estatísticos da MLP de modelo de predição da malha de temperatura da água de resfriamento das bicas, na ausência de defeitos.

Variáveis	Etapas de treinamento, verificação e validação
Média do resíduo	0,02 %
Desvio padrão do resíduo	1,14 %
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-3,4 a 3,4] %
Média do resíduo absoluto	0,76 %
Coeficientes de correlação do modelo: treinamento/verificação/validação	0,886 / 0,904 / 0,895, respectivamente

Uma segunda validação foi realizada na MLP. Foram coletados 6.500 novos padrões de operação. As Figuras 4.41 (a, b, c, d, e) mostram estes sinais.




Figura 4.41 a: Temperatura da água de resfriamento na entrada das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos.






Figura 4.41 b: Vazão total de água de resfriamento das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos.




Figura 4.41 c: Temperatura média da água de resfriamento na saída das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos.






Figura 4.41 d: Diferença de temperatura da água de resfriamento entre a entrada e a saída das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos.




Figura 4.41 e: Saída do controlador de temperatura da água de resfriamento das bicas para a etapa de segunda validação da MLP de predição da malha de temperatura da água de resfriamento das bicas, livre de defeitos.



A Figura 4.42 apresenta a comparação entre os sinais reais (medidos no processo, na ausência de defeitos) com os sinais inferidos pela MLP, das saídas do controlador de temperatura da água de resfriamento da água das bicas de fundidos na etapa de segunda validação. A Figura 4.43 apresenta os resíduos nesta mesma etapa.




Figura 4.42: Sinais reais e inferidos pela MLP para a saída do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de segunda validação da MLP de previsão da malha de temperatura da água de resfriamento das bicas.




Figura 4.43: Resíduos das saídas do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, da etapa de segunda validação da MLP de previsão da malha de controle da temperatura da água de resfriamento das bicas.



A Tabela 4.22 apresenta os resultados estatísticos da MLP de predição para a etapa de segunda validação e compara estes resultados com os das etapas de treinamento, verificação e validação.

Tabela 4.22: Comparação dos resultados estatísticos da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas, entre as etapas de segunda validação e treinamento, verificação e validação.

Variáveis	Etapa da segunda validação	Etapas de treinamento, verificação e validação
Média do resíduo	-0,13 %	0,02%
Desvio padrão do resíduo	0,93 %	1,14%
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-2,9 a 2,7] %	[-3,4 a 3,4] %

A Figura 4.44 apresenta os sinais reais e inferidos pela MLP das saídas do controlador de temperatura da água de resfriamento das bicas de fundidos, nas duas etapas, treinamento, verificação e validação e segunda validação. A Figura 4.45 apresenta os resíduos nas duas etapas.




Figura 4.44: Sinais reais e inferidos pela MLP das saídas do controlador de temperatura da água de resfriamento das bicas, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da temperatura da água de resfriamento das bicas.






Figura 4.45: Resíduos das saídas do controlador da temperatura da água de resfriamento das bicas, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle de temperatura da água de resfriamento das bicas. A faixa representa o intervalo compreendido entre a média  $\pm 3$  desvios padrão.

O treinamento da MLP de classificação de resíduos foi realizado com dados sem defeitos e dados defeituosos. Estes foram gerados por meio da MLP de predição, com a inserção de erros nos sinais das variáveis. Para minimizar a taxa de alarmes falsos na MLP de classificação foram inseridos erros para resíduos maiores que o intervalo de  $[-3,4$  a  $3,4]$ .

A Tabela 4.23 mostra as características da MLP de classificação de resíduos e a Figura 4.46, sua estrutura simplificada.

Tabela 4.23: Características da MLP de classificação dos resíduos da malha de controle de temperatura da água de resfriamento das bicas.

Número de unidades na primeira camada	3
Número de unidades na camada intermediária	6
Número de unidades na última camada	1
Variáveis de entrada selecionadas	TAGB, TMED, RESIDUO
Variável de saída	CLAS






Figura 4.46: Estrutura simplificada da MLP de classificação dos resíduos da malha de controle da temperatura da água de resfriamento das bicas.

O desempenho da MLP de classificação, nas etapas de treinamento, verificação e validação, foi determinado pela taxa de classificação correta dos resíduos. A Tabela 4.24 mostra que a MLP conseguiu classificar corretamente 99,9% dos dados do treinamento, 99,9% dos dados da verificação e 99,8% dos dados da validação.

Tabela 4.24: Desempenho da MLP de classificação dos resíduos da malha de controle de temperatura da água de resfriamento das bicas.

	Etapas					
	Treinamento		Verificação		Validação	
	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos
Dados totais	8508	16389	4180	8268	3910	8539
Dados com classificação correta	8498	16368	4174	8256	3903	8526
Dados com classificação errada	10	21	6	12	7	13
% de dados com classificação correta	99,9		99,9		99,8	
% de dados com classificação errada	0,01		0,01		0,02	

As duas redes neurais foram configuradas em programa Excel para o monitoramento do sistema de resfriamento da água das bicas de fundidos. A Figura 4.47 apresenta a tela principal do sistema de detecção.



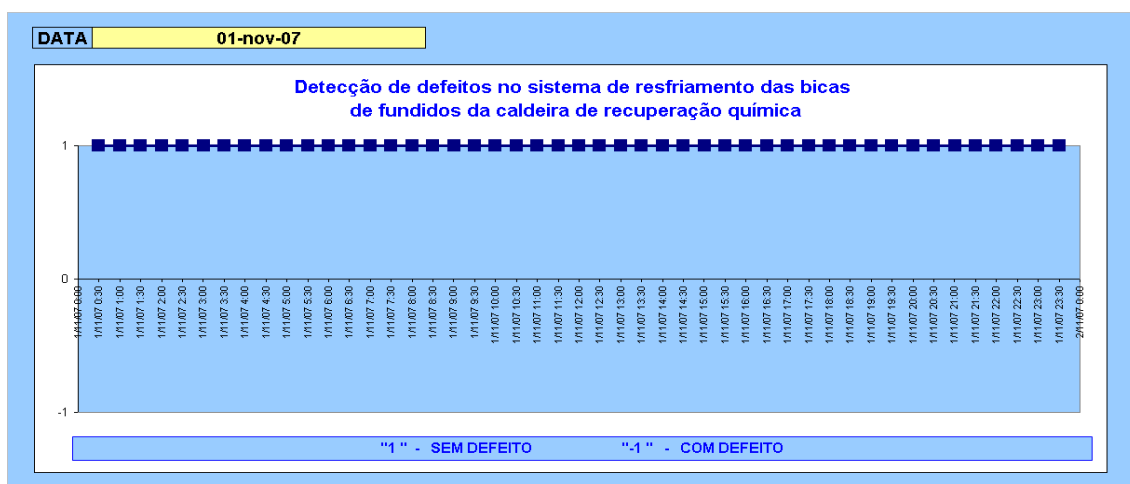


Figura 4.47: Tela do sistema de detecção de defeitos do sistema resfriamento das bicas de fundidos da caldeira de recuperação química.

O método foi utilizado para monitoramento do processo durante 65 dias. Neste período a taxa de alarmes falsos foi de 3,5 %.

A taxa de detecção do método foi determinada pela inserção de erros, de 1% a 20%, nos sinais de saída do controlador de temperatura da água de resfriamento das bicas de fundidos. A Figura 4.48 mostra a taxa de detecção do método versus a magnitude dos erros inseridos. Observa-se que o método foi capaz de detectar 49% do total de defeitos para erros de 6 % e 97% do total de defeitos para erros de 10 %.




Figura 4.48: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de temperatura da água de resfriamento das bicas.



#### 4.5. Malha de Controle da Pressão da Fornalha

As variáveis de influência pré-definidas para a modelagem desta malha foram: vazão de sólidos secos totais do licor negro (TSSH); pressão diferencial da caldeira no lado gases (PDTC); pressão da fornalha (PFOR); corrente dos ventiladores de tiragem (CORV); vazão de ar total da caldeira (VATT); índice de entupimento lado gases (INDE) e saída do controlador de pressão da fornalha (ROTA). De acordo com a Figura 2.12 d, é assumido que:

$$INDE = \left( \frac{VATT}{VATTMAX} \right) * \left( \frac{PDTBMAX}{PDTB} \right)^{\frac{1}{2}} \quad (4.3)$$

em que,

VATT: vazão de ar total da caldeira;

VATTMAX: vazão de ar total máximo da caldeira, 257.000 Nm<sup>3</sup>/h;

PDTBMAX: pressão diferencial máxima dos gases no banco de tubos da caldeira, igual a 7 mmCA;

PDTB: pressão diferencial dos gases no banco de tubos da caldeira;

As Figuras 4.49 (a, b, c, d, e, f, g) mostram os sinais das variáveis apresentadas a MLP. Eles são valores médios, de um período de trinta minutos, das variáveis de processo. Os dados foram coletados durante operação normal do processo produtivo, na ausência de defeitos. Para a construção da MLP de predição foram utilizados 14.091 padrões, que correspondem a 293 dias de operação.






Figura 4.49 a: Vazão de sólidos totais secos do licor negro para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos.




Figura 4.49 b: Pressão diferencial da caldeira para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos.






Figura 4.49 c: Pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de pressão da fornalha, livre de defeitos.




Figura 4.49 d: Corrente dos motores dos ventiladores de tiragem para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle pressão da fornalha, livre de defeitos.






Figura 4.49 e: Vazão de ar total para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos.




Figura 4.49 f: Índice de entupimento no lado gases para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos.






Figura 4.49 g: Saída do controlador da pressão da fornalha para as etapas de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos.

Tabela 4.25.: Características dos dados utilizados para o treinamento da MLP de predição da malha de controle da pressão da fornalha.

Variável	Etapa de treinamento, verificação e validação			
	Média	Desvio padrão	Valor máximo	Valor mínimo
TSSH	65,15	5,51	77,63	40,00
PDTC	85,90	12,52	136,24	2,74
PFOR	4,18	1,21	14,98	-10,48
CORV	46,95	4,03	60,22	31,54
VATT	301.650	10.221	324.323	237.969
INDE	1,01	0,11	2,40	0,53
ROTA	68,45	4,44	80,65	44,59

A Tabela 4.26 apresenta as características da MLP de predição do sistema de controle da pressão da fornalha e a Figura 4.50 mostra a sua estrutura simplificada.



Tabela 4.26: Características das variáveis para treinamento da MLP de predição da malha de controle da pressão da fornalha.

Número de unidades na primeira camada	6
Número de unidades na camada intermediária	8
Número de unidades na última camada	1
Variáveis de entrada selecionadas	TSSH, PDTC, PFOR, CORV, VATT e INDE
Variável de saída	ROTA




Figura 4.50: Estrutura simplificada da MLP de predição da malha de controle da pressão da fornalha, livre de defeitos.

A Figura 4.51 mostra a comparação entre os sinais medidos no processo e os sinais de saída da MLP, para as etapas de treinamento, verificação e validação. A Figura 4.52 apresenta os resíduos destas etapas.






Figura 4.51: Sinais reais e inferidos pela MLP para a saída do controlador de pressão da fornalha, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha.




Figura 4.52: Resíduos das saídas do controlador de pressão da fornalha, livre de defeitos, da etapa de treinamento, verificação e validação da MLP de predição da malha de controle da pressão da fornalha.

A Tabela 4.27 apresenta resultados estatísticos da MLP de predição. O resíduo médio, na ausência de defeitos, é de -0,01 %, com desvio padrão de 0,89%. Considerando o intervalo compreendido entre a média do resíduo  $\pm$  três desvios padrão, têm-se [-2,69 a 2,68].



Tabela 4.27: Resultados estatísticos da MLP de modelo de predição da malha de controle da pressão da fornalha, na ausência de defeitos.

Variáveis	Etapas de treinamento, verificação e validação
Média do resíduo	-0,01 %
Desvio padrão do resíduo	0,89 %
Intervalo do resíduo médio $\pm 3$ desvios padrão	[-2,69 a 2,68] %
Média do resíduo absoluto	0,67 %
Coeficientes de correlação do modelo: treinamento/verificação/validação	0,980 / 0,979 / 0,979, respectivamente

Uma segunda validação foi realizada na MLP. Foram coletados 3.595 novos padrões de operação. As Figuras 4.53 (a, b, c, d, e, f, g) mostram estes sinais.




Figura 4.53 a: Vazão de sólidos totais secos do licor negro para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.






Figura 4.53 b: Pressão diferencial da caldeira para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.




Figura 4.53 c: Pressão da fornalha para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.






Figura 4.53 d: Corrente dos motores dos ventiladores de tiragem dos gases para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.




Figura 4.53 e: Vazão de ar total para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.






Figura 4.53 f: Índice de entupimento dos gases para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.




Figura 4.53 g: Saída do controlador da pressão da fornalha para a etapa de segunda validação da MLP de predição da malha da pressão da fornalha, livre de defeitos.



A Figura 4.54 apresenta a comparação entre os sinais reais (medidos no processo, na ausência de defeitos) com os sinais inferidos pela MLP, das saídas do controlador da pressão da fornalha na etapa de segunda validação. A Figura 4.55 apresenta os resíduos nesta mesma etapa.




Figura 4.54: Sinais reais e inferidos pela MLP para a saída do controlador da pressão da fornalha, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de pressão da fornalha.






Figura 4.55: Resíduos das saídas do controlador da pressão da fornalha, livre de defeitos, da etapa de segunda validação da MLP de predição da malha de controle da pressão da fornalha.

A Tabela 4.28 apresenta os resultados estatísticos da MLP de predição para a etapa de segunda validação e compara estes resultados com os das etapas de treinamento, verificação e validação.

Tabela 4.28: Comparação dos resultados estatísticos da MLP de predição da malha de controle da pressão da fornalha, entre as etapas de segunda validação e treinamento, verificação e validação.

Variáveis	Etapas da segunda validação	Etapas de treinamento, verificação e validação
Média do resíduo	0,32 %	-0,01%
Desvio padrão do resíduo	0,70 %	0,89%
Intervalo do resíduo médio $\pm$ 3 desvios padrão	[-1,8 a 2,4] %	[-2,7 a 2,7] %

A Figura 4.56 apresenta os sinais reais e inferidos pela MLP das saídas do controlador de pressão da fornalha, nas duas etapas, treinamento, verificação e validação e segunda validação. A Figura 4.57 apresenta os resíduos nas duas etapas.






Figura 4.56: Sinais reais e inferidos pela MLP das saídas do controlador da pressão da fornalha, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da pressão da fornalha.




Figura 4.57: Resíduos das saídas do controlador da pressão da fornalha, livre de defeitos, das etapas de treinamento, verificação e validação (em azul escuro) e da segunda validação (em azul claro) da MLP de predição da malha de controle da pressão da fornalha. A faixa representa o intervalo compreendido entre a média  $\pm 3$  desvios padrão.



O treinamento da MLP de classificação de resíduos foi realizado com dados sem defeitos e dados defeituosos. Estes foram gerados por meio da MLP de predição, com a inserção de erros nos sinais das variáveis. Para minimizar a taxa de alarmes falsos na MLP de classificação, foram inseridos erros para resíduos maiores que o intervalo de  $[-2,7$  a  $2,7]$ .

A Tabela 4.29 mostra as características da MLP de classificação de resíduos e a Figura 4.58, sua estrutura simplificada.

Tabela 4.29: Características da MLP de classificação dos resíduos da malha de controle da pressão da fornalha.

Número de unidades na primeira camada	7
Número de unidades na camada intermediária	15
Número de unidades na última camada	1
Variáveis de entrada selecionadas	TSSH, PDTC, PFOR, CORV, VATT, INDE e RESIDUO
Variável de saída	CLAS




Figura 4.58: Estrutura simplificada da MLP de classificação dos resíduos da malha de controle da pressão da fornalha.

O desempenho da MLP de classificação, nas etapas de treinamento, verificação e validação, foi determinado pela taxa de classificação correta dos resíduos. A Tabela 4.30 mostra que a MLP conseguiu classificar corretamente 97,9% dos dados do treinamento, 98,0% dos dados da verificação e 97,7% dos dados da validação.



Tabela 4.30: Desempenho da MLP de classificação dos resíduos da malha de controle da pressão da fornalha.

	Etapas					
	Treinamento		Verificação		Validação	
	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos	Sem defeitos	Com defeitos
Dados totais	9219	17310	4296	8968	4171	9094
Dados com classificação correta	9027	16947	4204	8793	4080	8882
Dados com classificação errada	192	363	92	175	91	212
% de dados com classificação correta	97,9		98,0		97,7	
% de dados com classificação errada	2,1		2,0		2,3	

As duas redes neurais foram configuradas em programa Excel para o monitoramento do sistema de controle da pressão da fornalha. A Figura 4.59 apresenta a tela principal do sistema de detecção.




Figura 4.59: Tela do sistema de detecção de defeitos de controle da pressão da fornalha.

O método foi utilizado para monitoramento do processo durante 75 dias. Neste período, a taxa de alarmes falsos foi de 1,4 %.

A taxa de detecção do método foi determinada pela inserção de erros, de 1% a 20%, nos sinais de saída do controlador de pressão da fornalha. A Figura 4.60 mostra a taxa de detecção do método versus a magnitude dos erros inseridos. Observa-se que o



método foi capaz de detectar 99,8% do total de defeitos para erros de 4 % e 98,9% do total de defeitos para erros de -4 %.




Figura 4.60: Taxa de detecção de defeitos versus a magnitude dos erros inseridos nos sinais de saída do controlador de pressão da fornalha.

#### 4.6. Discussão

A MLP conseguiu prever o comportamento das malhas de controle da caldeira de recuperação química. A Tabela 4.31 apresenta a comparação do resíduo médio, desvio padrão do resíduo e intervalo da média  $\pm 3$  desvios padrão, da etapa de segunda validação, para as malhas de controle de vazão de ar primário, secundário, terciário, de temperatura da água de resfriamento das bicas de fundidos e da pressão da fornalha.

Tabela 4.31: Comparação dos resultados das MLP's de predição.

Variáveis na etapa de segunda validação	Ar primário	Ar secundário	Ar terciário	Temperatura da água das bicas	Pressão da fornalha
Resíduo médio (%)	0,38	-1,13	-0,59	-0,13	0,32
Desvio padrão do resíduo (%)	4,38	3,67	3,2	0,93	0,7
Intervalo (média do resíduo $\pm 3$ desvios padrão)	-12,8 a 13,5	-12,1 a 9,9	-10,2 a 9,1	-2,9 a 2,7	-1,8 a 2,4



A MLP de classificação conseguiu classificar os resíduos. Na Tabela 4.32 são apresentados os resultados das taxas de classificação correta dos dados, da etapa de validação, para as malhas analisadas.

Tabela 4.32: Comparação dos resultados das MLP's de classificação.

Variáveis na etapa de validação	Ar primário	Ar secundário	Ar terciário	Temperatura da água das bicas	Pressão da fornalha
Taxa de classificação correta dos dados (%)	98,5	96,3	95,7	99,8	97,7
Taxa de classificação errada dos dados (%)	1,5	3,7	4,3	0,02	2,3

O método foi utilizado para monitoramento do processo durante operação normal. A Tabela 4.33 apresenta as taxas de alarmes falsos para as malhas analisadas.

Tabela 4.33: Comparação das taxas de alarmes falsos para as malhas analisadas.

Variáveis	Ar primário	Ar secundário	Ar terciário	Temperatura da água das bicas	Pressão da fornalha
Taxa de alarmes falsos (%)	5,0	4,0	0,2	3,5	1,4
Período de monitoramento (dias)	88	66	65	65	75

A taxa de detecção foi determinada pela simulação de erros de 1 a 20 % nas variáveis de processo. A Figura 4.61 apresenta as taxas de detecção em função dos erros simulados para as malhas analisadas.






Figura 4.61: Taxas de detecção de defeitos das malhas analisadas.

Pela Figura 4.61 observa-se que as curvas não são centralizadas. Isso ocorre porque o resíduo médio, na ausência de defeitos, para a base de dados de monitoramento, não é exatamente zero.

A menor taxa de detecção de defeitos do sistema de ar terciário é devido à dificuldade de se modelar esta malha com boa precisão, associada com a menor taxa obtida para classificação correta dos dados, em relação às demais malhas de controle. Ainda assim, a taxa de detecção dos defeitos foi de 52,6% para erros de 16% e de 98,1% para erros de -16%.

Pelos resultados apresentados o método demonstrou características de sensibilidade, robustez e velocidade para a detecção de defeitos incipientes e se apresenta como uma ferramenta para suporte operacional.



## **5. CONCLUSÕES E SUGESTÕES DE ESTUDOS**

### **5.1. Conclusões**

O objetivo desta tese é propor uma metodologia, baseada em redes neurais artificiais, para a detecção de defeitos incipientes de uma caldeira de recuperação química. A metodologia foi aplicada nas malhas de controle de ar primário, secundário e terciário, no controle da temperatura da água de resfriamento das bicas de fundidos e no controle da pressão da fornalha de uma caldeira de recuperação química.

Pelos resultados apresentados o método demonstrou características de sensibilidade, robustez e velocidade para a detecção de defeitos incipientes e se apresenta como uma ferramenta para suporte operacional.

### **5.2. Sugestões de Estudos**

- Aplicar o método para a segunda caldeira de recuperação química da empresa em estudo e comparar os resultados.
- Aplicar o método para a caldeira de biomassa da empresa em estudo e comparar os resultados com as caldeiras de recuperação química.
- Aplicar o método para a caldeira de biomassa da empresa em estudo, utilizando dados gerados pelo simulador de processo da caldeira, disponível na empresa em estudo, e comparar os resultados com os casos anteriores.



## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMS, T.N., FREDERICK, W.J., GRACE, T.M., HUPA, M., IISA, K., JONES, A.K., TRAN, H. *Kraft Recovery Boilers*. New York: TAPPI Press, 1997. 381 p.
- ALESSANDRI, A. Fault diagnosis for nonlinear systems using a bank of neural estimators. *Computers in Industry*, v. 52, p. 271-289, 2003.
- ALMEIDA, G.M. *Deteção de situações anormais em caldeiras de recuperação química*. Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo, São Paulo, 2006.
- ANGELOV, P, GIGLIO, V., GUARDIOLA, C., LUGHOFFER, E., LUJAN, J.M. An approach to model-based fault detection in industrial measurement systems with application to engine test benches. *Measurement Science and Technology*, v. 17, p. 1809-1818, 2006.
- BASSEVILLE, M., BENVENISTE, A., MOUSTAKIDES, G., ROUGE, A. Detection and diagnosis of changes in the eigenstructure of nonstationary multivariable systems. *Automatica*, v. 23, p. 479-489, 1987.
- BEARD, R.V. *Failure accommodation in linear systems through self-reorganization*. Relatório - Massachusetts Institute Technology, Cambridge, 1971.
- BENVENISTE, A., BASSEVILLE, M., MOUSTAKIDES, G. The asymptotic local approach to change detection and model validation. *IEEE Trans. on Automatic Control*, v. 32, p. 583-592, 1987.
- BHAT, N., MCAVOY, T.J. Determining model structure for neural models by network stripping. *Computers Chemical Engineering*, v. 16, n. 4, p. 271-281, 1992.
- BRACELPA (Associação Brasileira de Celulose e Papel), Disponível em: <<http://www.bracelpa.org.br/>>. Acesso em: 02 mai. 2005.
- BRAGA, A.P., LAUDEMIR, T.B., CARVALHO, A. *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: Livros Técnicos e Científicos, 2000.
- BUENO, E.I. *Utilização de redes neurais artificiais na monitoração e detecção de falhas em sensores do reator IEA-R1*. Tese (Mestrado) - Instituto de



Pesquisas Energéticas e Nucleares da Universidade de São Paulo, São Paulo, 2006.

- CHEN, J., PATTON, R.J., ZHANG, H. Design of unknown input observers and robust fault detection filters. *International Journal of Control*, v. 63, n. 1, p. 85-105, 1996.
- CHOW, E.T., WILLSKY, A.S. Analytical redundancy and the design of robust failure detection systems. *IEEE Trans. On Automatic Control*, v. 29, p. 603-614, 1984.
- CLARK, R.N., FOSTH, D.C., WALTON, W.M. Detecting instrument malfunctions in control systems. *IEEE Trans. on Aerospace and Electronic Systems*, v. 11, p. 465-473, 1975.
- CYBENKO, G. Approximation by superposition of a sigmoidal function. *Mathematics of Control, Signals and Systems*, v. 2, p. 303-314, 1989.
- DECKERT, J.C., DESAI, M.N., DEYST, J.J., WILLSKY, A.S. F-8 DFBW sensor failure detection using analytical redundancy. *IEEE Trans. on Automatic Control*, v. 22, p. 795-803, 1977.
- DESAI, M., RAY, A. A fault detection and isolation methodology – Theory and application. In: AMERICAN CONTROL CONFERENCE, 1984, San Diego.
- EFRATI, H.F.T. Tracking of mechanical systems using artificial neural networks. *Revista Brasileira de Ciências Mecânicas*, v.19, n. 2, p. 217-227, 1997.
- FAGARASAN, I., PLOIX, S., GENTIL, S. Causal fault detection and isolation based on a set-membership approach. *Automatica*, v. 40, p. 2099-2110, 2004.
- FRANK, P.M., DING, S.X., MARCU, T. Model-based fault diagnosis in technical process. *Transactions of the Institute of Measurement and Control*, v. 22, n. 1, p. 57-101, 2000.
- FRANK, P.M., DING, X. Survey of robust residual generation and evaluation methods in observer-based fault detection systems. *Journal of Process Control*, v. 7, n. 6, p. 403-424, 1997.
- FRANK, P.M., KELLER, L. Sensitivity discriminating observer design for instrument failure detection. *IEEE Trans. on Aerospace and Electronic Systems*, v. 16, p. 460-467, 1980.



- FRIEDLAND, B., Maximum likelihood estimation of a process with random transitions (failures). *IEEE Trans. on Automatic Control*, v. 24, p. 932-937, 1979.
- FRISK, E. *Residual generation for fault diagnosis: nominal and robust design*. Tese - Department of Electrical Engineering of Linköping University, Sweden, 1998.
- GERTLER, J.J. Fault detection and isolation using parity relations. *Control Engineering Practice*, v. 5, n. 5, p. 653-661, 1997.
- GERTLER, J.J. *Fault detection and diagnosis in engineering systems*. New York: Marcel Dekker, 1998. 484 p.
- GERTLER, J., FANG, X., LUO, Q. Detection and diagnosis of plant failures – The orthogonal parity equation approach. *Advances in Control and Dynamic Systems*, v. 37, p. 159-216, 1990.
- GERTLER, J., SINGER, D. A new structural framework for parity equation based failure detection and isolation. *Automatica*, v. 26, p. 381-388, 1990.
- GREEN, R.P., HOUGH, G. *Chemical Recovery in the Alkaline Pulping Processes*. Atlanta: TAPPI Press, 1992. 189 p.
- GULLICHSEN, J., PAULAPURO, H. *Papermaking Science and Technology*, Fapet Oy, 1998.
- HAYKIN, S. *Neural networks – A comprehensive foundation*. Prentice Hall, 1999.
- HIMMELBLAU, D.M. *Fault detection and diagnosis in chemical engineering and petrochemical processes*. Chemical Engineering Monograph 8, Elsevier.
- HUPA, M., FREDERICK, W.J. Combustion of black liquor droplets. In: TAPPI KRAFT RECOVERY SHORT COURSE, 2001, Florida.
- ISERMANN, R., FREYERMUTH, B. Process fault diagnosis based on process model knowledge. *ASME Journal of Dynamic Systems, Measurement and Control*, v. 113, p. 620-626, 1991.
- ISERMANN, R. Mechatronic systems: concepts and applications. *Transactions of the Institute of Measurement and Control*, v. 22, n. 1, p. 29-55, 2000.
- ISERMANN, R. Mechatronic systems: concepts and applications. *Transactions of the Institute of Measurement and Control*, v. 22, n. 1, p. 29-55, 2000.



- JONES, H.L. *Failure detection in linear systems*. Tese (Ph.D.) – Massachusetts Institute Technology, Cambridge, 1973.
- KOLMOGOROV, S., KURKOVA, V. Theorem and multilayer neural networks. *Neural Networks*, v. 5, p. 501-506, 1992.
- LEININGER, G.G. Model degradation effects on sensor failure detection. In: AMERICAN CONTROL CONFERENCE, 1981, Blacksburg.
- LI, Y., PONT, M.J., JONES, N.B. Applying MLP and RBF classifiers in embedded condition monitoring and fault diagnosis systems. *Transactions of the Institute of Measurement and Control*, v. 23, n. 5, p. 215-343, 2001.
- LI, W., SHAH, S. Structured residual vector-based approach to sensor fault detection and isolation. *Journal of Process Control*, v. 12, p. 429-443, 2002.
- LOU, X.C, WILLSKY, A.S., VERGHESE, G.C. Optimally robust redundancy relations for failure detection in uncertain systems. *Automatica*, v. 22, p. 333-344, 1986.
- MAH, R.S., STANLEY, G.M., DOWNING, D.M. Reconciliation and rectification of process flow and inventory data. *Ind. Eng. Chemistry, Process Design*, v. 15, p. 175-183, 1976.
- MASSOUMNIA, M.A. A geometric approach to the synthesis of failure detection filters. *IEEE Trans. on Automatic Control*, v. 31, p. 839-846, 1986.
- MASSOUMNIA, M.A., VELDE, W.E.V. Generating parity relations for detecting and identifying control system component failures. *Journal of Guidance, Control and Dynamics*, v. 11, n. 1, p. 60-65, 1988.
- MEHRA, R.K., PESCHON, J. An innovations approach to fault detection in dynamic systems. *Automatica*, v. 7, p. 637-640, 1971.
- MIRONOVSKII, L.A. Functional diagnosis of linear dynamic systems. *Avtomatika i Telemekhanika*, v. 40, p. 1198-1205, 1979.
- NIKOUKHAH, R. Innovations generation in the presence of unknown inputs: application to robust failure detection. *Automatica*, v. 30, p. 1851-1867, 1994.
- PARISINI, T. Physically accurate nonlinear models for faulty detection and diagnosis: the case of a power plant. *Journal of Process Control*, v. 7, n. 2, p. 97-109, 1997.



- PATAN, K., PARISINI, T. Identification of neural dynamical models for fault detection and isolation: the case of a real sugar evaporation process. *Journal of Process Control*, v. 15, p. 67-69, 2005.
- PATTON, R.J., CHEN, J. A review of parity space approaches to fault diagnosis. In: PREPRINTS OF 2° IFAC SAFEPROCESS SYMPOSIUM, 1991, Helsinki.
- POTTER, J.E., SUMAN, M.C. Thresholdless redundancy management with arrays of skewed instruments. *Integrity in Electronic Flight Control Systems*, AGARDograph-224, p. 15.1-15.25, 1977.
- ROMAGNOLI, J.A., STEPHANOPOULOS, G. Rectification of process measurement data in the presence of gross errors. *Chemical Engineering Science*, v. 36, p. 1849-1863, 1981.
- RUZ-HERNANDEZ, J.A. *Development and application on a neural network-based scheme for fault detection and diagnosis in fossil electric power plants*. Tese (PhD) - CINVESTAVIPN, Guadalajara Campus, México, 2006.
- RUZ-HERNANDEZ, J.A., SANCHEZ, E., SUAREZ, D.A. Fault detection and diagnosis for fossil electric power plants via recurrent neural networks. *Dynamics of Continuous, Discrete and Impulsive Systems – Serie B: Applications & Algorithms*, v. 15, p. 219-256, 2008.
- SU, H., MCAVOY, T. J., WERBOS, P. Long term predictions of chemical processes using recurrent neural networks: A parallel training approach. *Industrial Engineering Chemical Research*, v. 31, n. 5, p. 1338-1352, 1992.
- STAROSWIECKI, M., CASSAR, J.P., COCQUEMPOT, V. Generation of optimal structured residuals in the parity space. In: IFAC 12<sup>th</sup> WORLD CONGRESS, 1993, Sydney.
- STATSOFT, Disponível em: <<http://www.statsoft.com/>>. Acesso em: 1 jul. 2008.
- TAPPI: KRAFT RECOVERY SHORT COURSE, 2001, Florida. Anais: Course Notes. Florida, 2001.
- TINOS, R. *Detecção e diagnóstico de falhas em robôs manipuladores via redes neurais artificiais*. Tese (Mestrado) - Escola de Engenharia de São Carlos, São Carlos, 1999.



- VACLAVEK, V. Gross systematic errors or biases in the balance calculations. *Papers of the Prague Institute of Technology*, Praga, 1974.
- VENKATASUBRAMANIAN, V., RENGASWAMY, R., YIN, K., KAVURI, S.N. A review of process fault detection and diagnosis: part I: quantitative model-based methods. *Comput Chemical Engineering*, v. 27, p. 293-311, 2003.
- VENKATASUBRAMANIAN, V., RENGASWAMY, R., YIN, K., KAVURI, S.N. A review of process fault detection and diagnosis: part II: qualitative models and search strategies. *Comput Chemical Engineering*, v. 27, p. 313-326, 2003.
- VENKATASUBRAMANIAN, V., RENGASWAMY, R., YIN, K., KAVURI, S.N. A review of process fault detection and diagnosis: part III: process history based methods. *Comput Chemical Engineering*, v. 27, p. 327-346, 2003.
- VISWANADHAM, N. SRICHANDER, R. Fault detection using unknown input observers. *Control – Theory and Advanced Technology*, v. 3, p. 91-101, 1987.
- VISWANADHAM, N. TAYLOR, J.H., LUCE, E.C. A frequency domain approach to failure detection and isolation with application to GE-21 turbine engine control system. *Control – Theory and Advanced Technology*, v. 3, p. 45-72, 1987a.
- WHITE, J.E., SPEYER, J.L. Detection filter design: Spectral theory and algorithms. *IEEE Trans. on Automatic Control*, v. 32, p. 593-603, 1987.
- WILLSKY, A.S. A survey of design methods for failure detection in dynamic systems. *Automatica*, v. 12, p. 601-611, 1976.
- WILLSKY, A.S., JONES, H.L. A generalized likelihood ratio approach to detection and estimation of jumps in linear systems. *IEEE Trans. on Automatic Control*, v. 21, p. 108-112, 1976.
- ZHANG, Q., BASSEVILLE, M., BENVENISTE, A. Early warning of slight changes in systems. *Automatica*, v. 30, p. 95-113, 1994.



## APÊNDICE A

### Statística Neural Networks (SNN)

O objetivo deste apêndice é dar uma breve introdução sobre o programa Statística Neural Networks. Para pesquisa mais aprofundada sugere-se STATSOFT (Disponível em: <<http://www.statsoft.com/>>).

Para a construção das RNA desta tese foi utilizado o programa comercial Statística Neural Networks (SNN), versão quatro (4). Ele possui as seguintes características:

- Capacidade para solução de problemas de classificação, regressão e série temporal;
- Possibilidade de utilização de vários tipos de redes neurais: linear, perceptron com três camadas, perceptron com quatro camadas, base radial, probabilística e regressão generalizada;
- Possibilidade de utilização de vários algoritmos de treinamento: Gradiente Descendente Conjugado, Quasi-Newton, Levenberg-Marquardt, Retropropagação e Delta-Bar-Delta;
- Realização de processamento integrado dos dados, incluindo a divisão dos dados para as etapas de treinamento, validação e teste, a normalização dos dados e a substituição de dados desconhecidos (sem valor numérico);
- Ele possui o Intelligent Problem Solving (IPS), que é uma ferramenta para guiar o usuário no procedimento de criação de RNA;
- Controle completo do usuário sobre todos os aspectos que influenciam o desempenho da rede neural, como funções de erro e de ativação e complexidade da rede;
- Possibilidade de escolha de redes de tamanhos grandes, praticamente com número de neurônios ilimitado;
- Possibilidade de determinação da rede de melhor desempenho baseado em critérios de desempenho e de parada;
- Possibilidade de definição do tempo para o treinamento ou a utilização de tempos pré-definidos nas opções: rápido, médio, longo. Estas três opções não possuem



valor de tempo definido, mas é função da quantidade de dados e da complexidade da rede neural;

- Apresentação dos resultados de forma gráfica e com análise estatística;
- Programa que trabalha completamente integrado com programa comercial “Statistica”;

Há dois modos de operação do IPS, o modo básico e o modo avançado. O modo básico foi projetado para usuários que não tenham muita experiência com redes neurais. O usuário simplesmente especifica o tipo do problema, as variáveis que serão utilizadas, o tempo desejado para o treinamento, o número das redes que deverão ser selecionadas e salvas no conjunto de redes e os resultados estatísticos que se deseja. Já o modo avançado permite ao usuário controlar o processo de construção da rede, incluindo as características de como será a divisão do conjunto de dados entre subconjuntos de treinamento, verificação e teste; a atribuição dos níveis de confiança de classificação; a seleção do tipo e da complexidade da rede e a determinação do tempo de treinamento. O modo avançado foi projetado para valorizar o conhecimento do usuário na condução de um grande número de experimentos e selecionando as melhores redes neurais de forma automática. A função de ativação utilizada pelo SNN para o treinamento das redes do tipo MLP é a função logística. O critério utilizado pelo SNN para avaliação de desempenho das redes neurais é a função do erro, baseado no método de minimização da soma dos erros quadráticos.

### **Criando uma RNA, Através do SNN**

Após a abertura do arquivo de dados no SNN, através do IPS, inicia-se a configuração dos parâmetros para o projeto da rede neural. Basicamente, os problemas a serem resolvidos podem ser de regressão e de classificação. Nos problemas de regressão o objetivo é a predição de valores de uma variável de saída contínua. Nos problemas de classificação o objetivo é a atribuição das variáveis de entrada a uma determinada classe.



## Criando uma RNA para Problemas de Regressão, através do SNN

### a) Primeiro Passo: Escolha do Modo de Treinamento

A primeira decisão a ser tomada é a escolha do modo de treinamento: básico (“basic”) ou avançado (“advanced”).

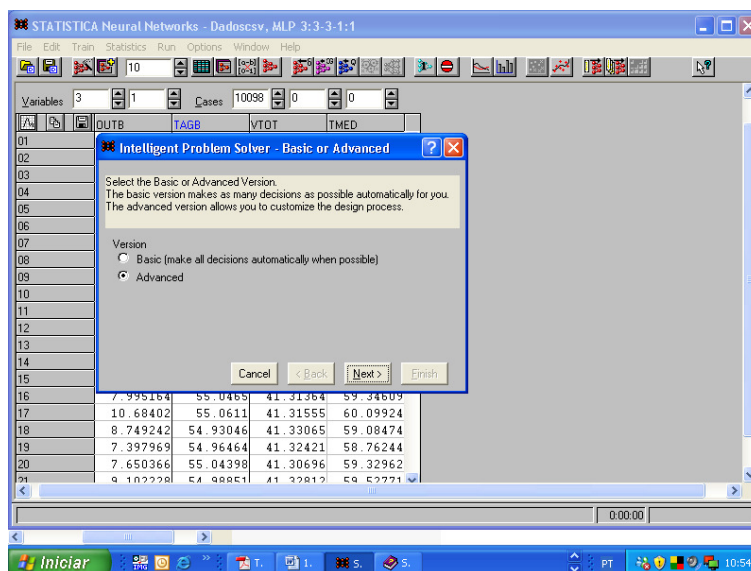


Figura A1.1: Tela do SNN para definição do modo de treinamento da RNA.

### b) Segundo Passo: Escolha do Tipo do Problema

Nesta etapa será definido o tipo do problema a ser resolvido, o convencional (“standard”) ou o de série temporal (“times series”). No treinamento convencional os pares de dados de entrada e saída são considerados independentes. No treinamento de série temporal os dados de entrada e saída são considerados como uma função de sua sequência (função do tempo), onde os valores preditos são baseados nos valores anteriores.



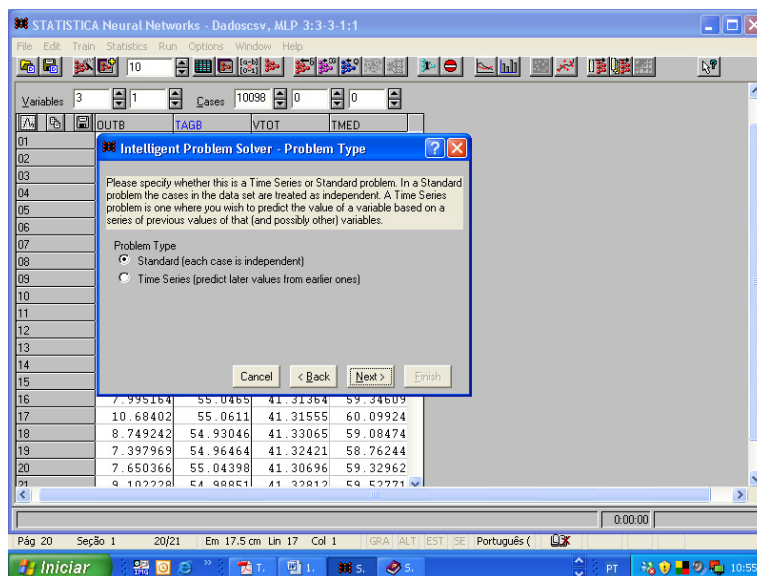


Figura A1.2: Tela do SNN para definição do tipo do problema.

### c) Terceiro Passo: Escolha da Variável de Saída

Nesta etapa será escolhida a variável de saída da rede, que é a variável que será a variável inferida. Para a sua escolha deve-se clicar na variável desejada. É possível escolher mais de uma variável de saída da rede, neste caso, deve-se clicar na opção de “múltiplas saídas” (“multiple”) no canto esquerdo inferior da tela.

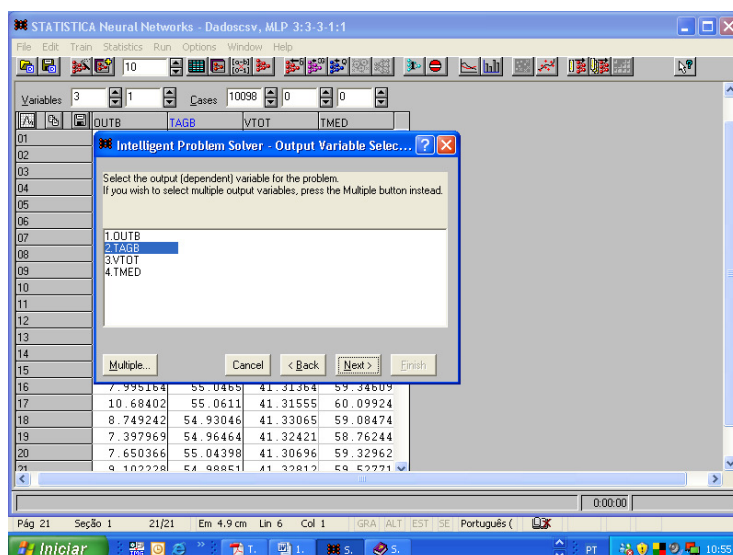


Figura A1.3: Tela do SNN para definição da variável de saída da RNA.



#### d) Quarto Passo: Escolha das Variáveis de Entrada

Nesta etapa serão escolhidas as variáveis de entrada da rede, que pode ser realizada de duas formas. Uma delas é determinação automática pelo SNN, baseado na correlação das variáveis de entrada com a variável de saída da rede. Para isso basta habilitar a opção “procura por um subconjunto efetivo das variáveis de entrada” (“search for an effective subset of the specified variables”). A outra forma é a escolha das variáveis de entrada pelo usuário. Para isso basta clicar nas variáveis desejadas e manter a opção “procura por um subconjunto efetivo das variáveis de entrada” (“search for an effective subset of the specified variables”) desabilitada.

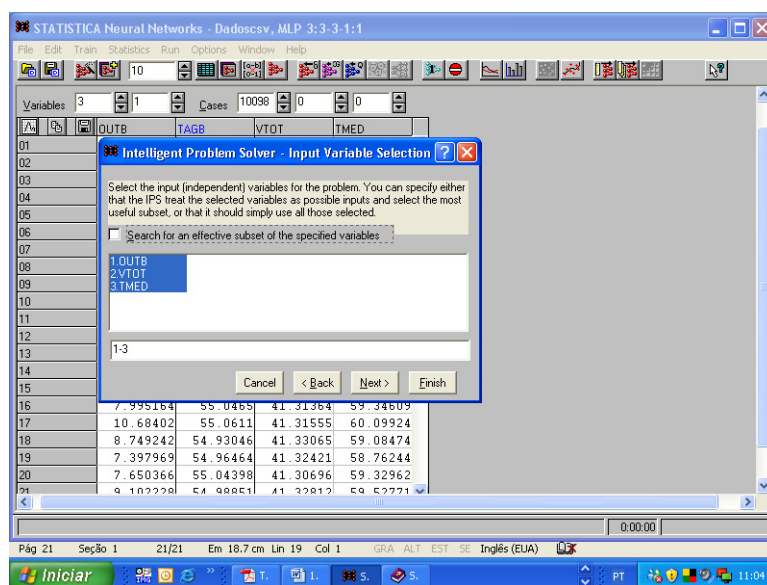


Figura A1.4: Tela do SNN para definição das variáveis de entrada da RNA.

#### e) Quinto Passo: Escolha da Divisão dos Dados

Nesta etapa os dados serão divididos em três subconjuntos: treinamento, verificação e teste. Há duas opções de divisão, a sugerida pelo SNN (“randomly reassign in numbers given below”) e a definida pelo usuário (“use current division of data set”). A primeira compreende a divisão aleatória dos dados em 50% para treinamento, 25% para verificação e 25% para teste. Na segunda o usuário poderá definir as quantidades de dados para as três etapas. O usuário pode também classificar os dados que serão utilizados nas etapas de treinamento, verificação e teste, ao invés de serem aleatórios.



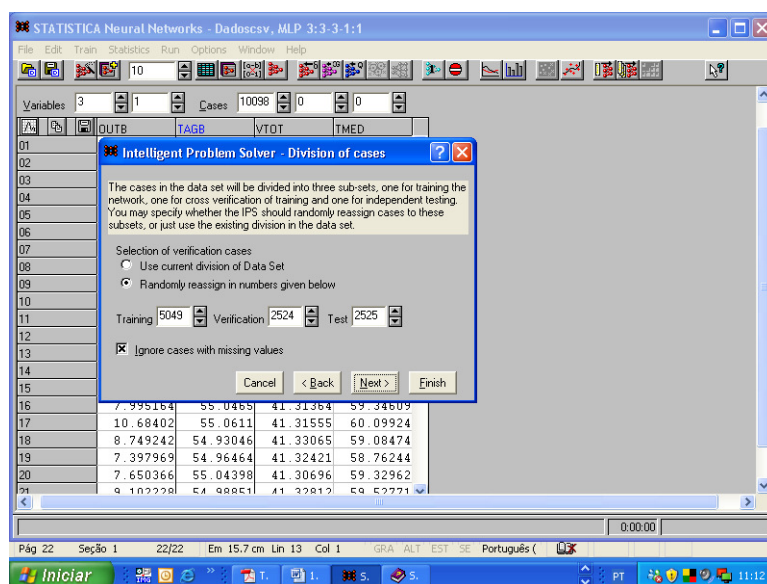


Figura A1.5: Tela do SNN para definição da divisão dos dados em treinamento, verificação e teste.

#### f) Sexto Passo: Escolha do Tipo da RNA

Nesta etapa é escolhido o tipo da rede neural para o treinamento. As opções de rede são: linear, PNN ou GRNN, RBF, MLP com três camadas e MLP com quatro camadas. É possível escolher mais de um tipo de rede neural para o treinamento.

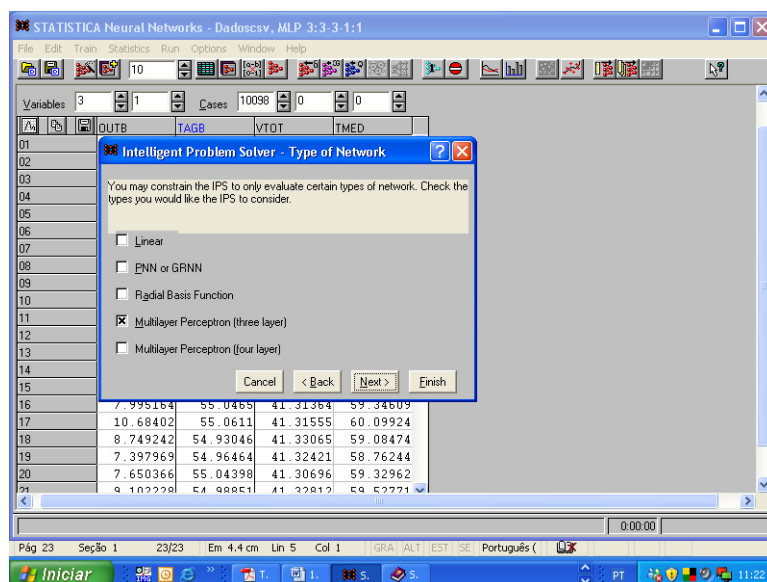


Figura A1.6: Tela do SNN para definição do tipo da RNA.



### g) Sétimo Passo: Determinação da Complexidade da RNA

Nesta etapa é determinada a complexidade da rede neural. O SNN possui duas formas para esta determinação: a automática ou a manual. A determinação automática é realizada pelo SNN através da comparação dos desempenhos das redes testadas. Para isto basta ativar a opção “determinação da complexidade da rede automaticamente” (“determine network complexity automatically”). Na opção manual o usuário define a complexidade da rede, com a opção automática desabilitada. Por exemplo, para a rede MLP com três camadas, a complexidade da rede será a determinação da quantidade de neurônios na camada intermediária.

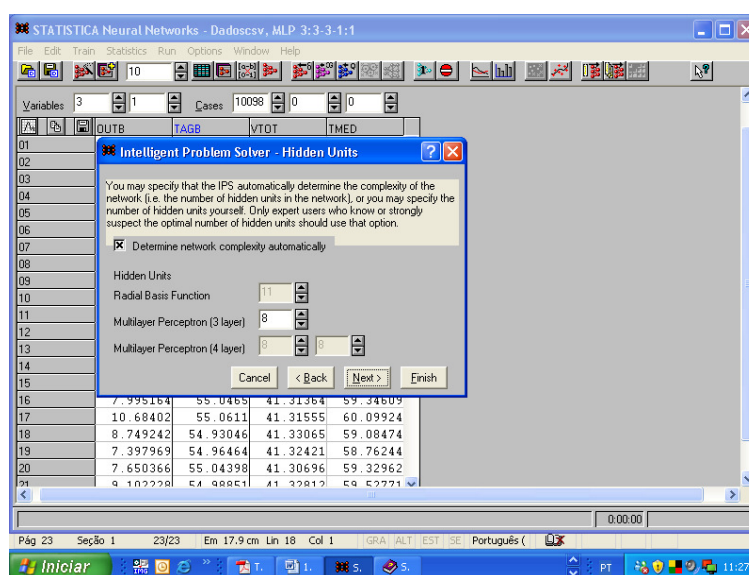


Figura A1.7: Tela do SNN para definição da complexidade da RNA.

### h) Oitavo Passo: Escolha da Duração do Treinamento

Nesta etapa é definida a duração do processo de treinamento. O limite máximo do programa é 9.999 horas e 59 minutos. Para definir o tempo do treinamento é necessário clicar na opção “escolha do tempo de duração” (“search until the duration specified below has expired”) e digitar o valor desejado. O SNN também possui três opções automáticas para a duração do treinamento: rápida, média e longa. E aconselhável a opção longa ou a definição de um tempo longo para o treinamento.



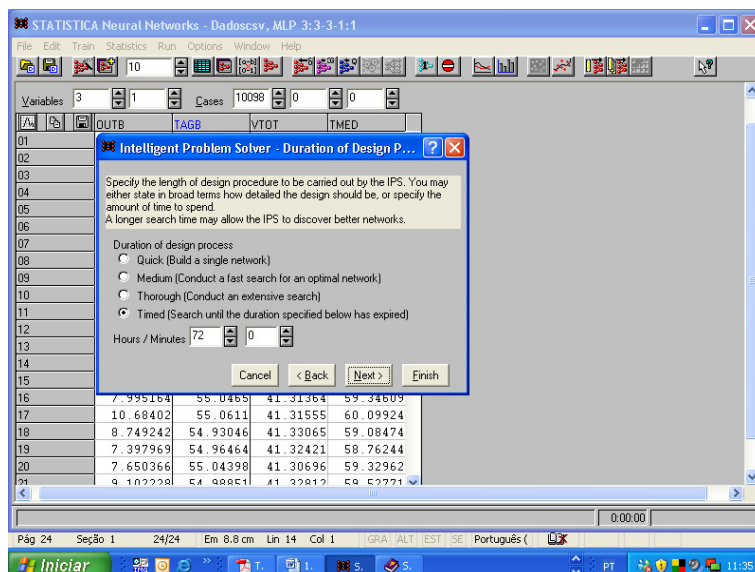


Figura A1.8: Tela do SNN para definição da duração do treinamento da RNA.

i) Nono Passo: Escolha da Apresentação Estatística dos Resultados Após a Criação da Rede

Nesta etapa são definidas as análises estatísticas desejadas para a apresentação dos resultados da rede: folha de dados dos resultados, resumo estatístico completo, e análise de sensibilidade da melhor rede.

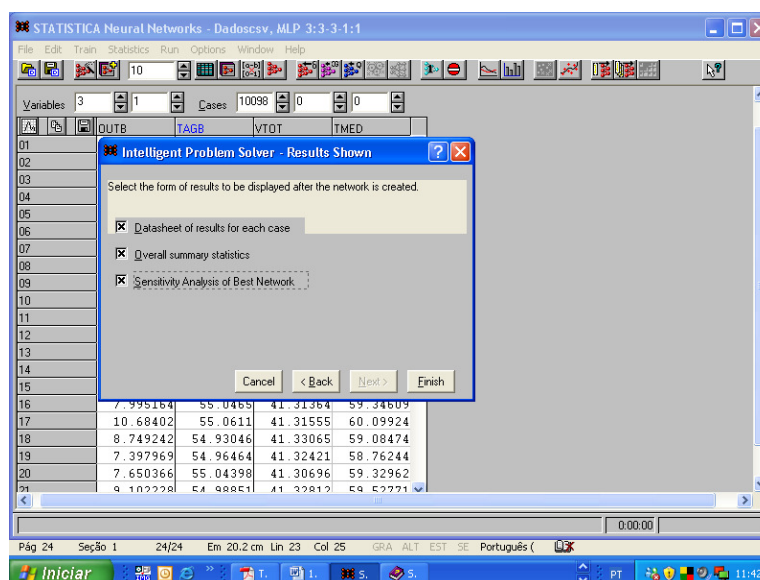


Figura A1.9: Tela do SNN para definição das análises estatísticas que serão apresentadas pelo SNN.

Após estas etapas o SNN treina um grande conjunto de redes e apresenta a de melhor desempenho.



## Criando uma RNA no SNN para Problemas de Classificação

O procedimento para criação de redes de classificação no SNN é similar à criação de redes de regressão, com exceção de que entre os passos “e” e “f” há um passo adicional, que é para a escolha dos limites de confiança.

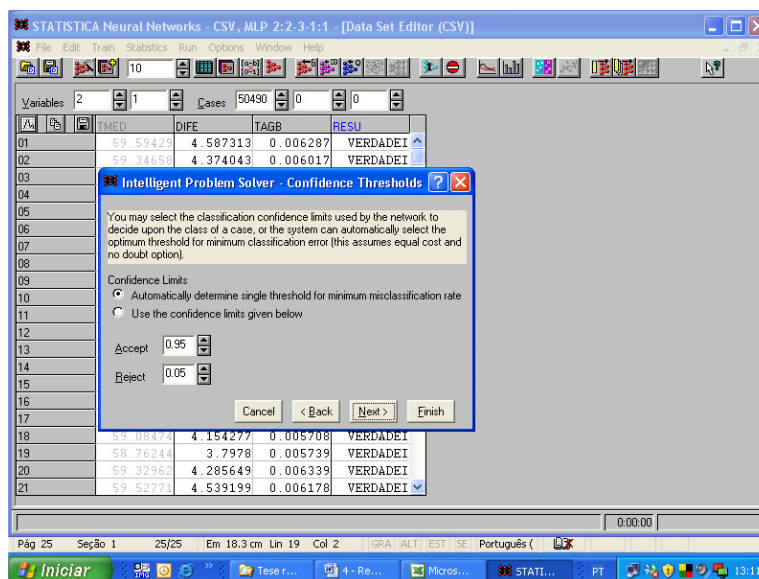


Figura A1.10: Tela do SNN para definição dos limites de confiança da rede neural artificial.

O SNN pode determinar os limites automaticamente para reduzir ao mínimo os erros de classificação. Para isso basta clicar na opção “determinar os limites de classificação para mínima taxa de classificação errada” (“automatically determine single threshold for minimum misclassification rate”)