

**UNIVERSIDADE FEDERAL FLUMINENSE  
ESCOLA DE ENGENHARIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA E DE PETRÓLEO**

**ALESSANDRA RIBEIRO SILVA**

**“ESTUDO PRELIMINAR DA APLICAÇÃO DE REDES NEURONAIS  
NO SISTEMA DE CONTROLE DE TEMPERATURA EM UMA  
PLANTA DIDÁTICA”**

**ALESSANDRA RIBEIRO SILVA**

**“ESTUDO PRELIMINAR DA APLICAÇÃO DE REDES  
NEURONAIS NO SISTEMA DE CONTROLE DE TEMPERATURA  
EM UMA PLANTA DIDÁTICA”**

Projeto Final apresentado ao Curso de Graduação em Engenharia Química, oferecido pelo departamento de Engenharia Química e de Petróleo da Escola de Engenharia da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Engenheiro Químico.

**ORIENTADORES:**

Prof<sup>ª</sup>. Ninoska Isabel Bojorge Ramirez

Prof. Álvaro José Boareto Mendes

Ficha Catalográfica elaborada pela Biblioteca da Escola de Engenharia e Instituto de Computação da UFF

S586 Silva, Alessandra Ribeiro

Estudo preliminar da aplicação de redes neuronais no sistema de controle de temperatura em uma planta didática / Alessandra Ribeiro Silva. -- Niterói, RJ : [s.n.], 2015.

79 f.

Trabalho (Conclusão de Curso) – Departamento de Engenharia Química e de Petróleo, Universidade Federal Fluminense, 2015.

Orientadores: Ninoska Isabel Bojorge Ramirez, Álvaro José Boareto Mendes.

1. Controle de processo químico. 2. Inteligência artificial. 3. Rede neuronal artificial. I. Título.

CDD 660.281

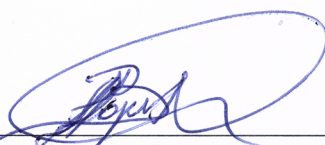
**ALESSANDRA RIBEIRO SILVA**

**“ESTUDO PRELIMINAR DA APLICAÇÃO DE REDES NEURONAIS  
NO SISTEMA DE CONTROLE DE TEMPERATURA EM UMA  
PLANTA DIDÁTICA”**

Projeto Final apresentado ao Curso de Graduação em Engenharia Química, oferecido pelo departamento de Engenharia Química e de Petróleo, da Escola de Engenharia, da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau em Engenharia Química.

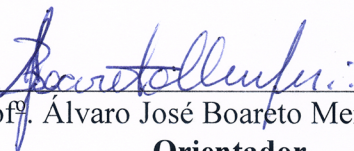
Aprovado em 9 de julho de 2015.

**BANCA EXAMINADORA**



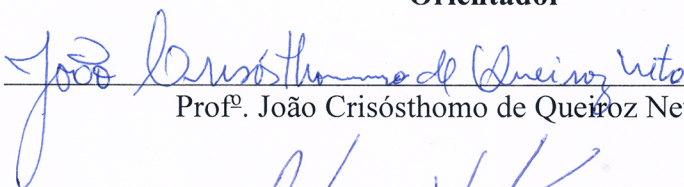
---

Prof<sup>ª</sup>. Ninoska Isabel Bojorge Ramirez, D.Sc.  
**Presidente da Banca – Orientadora**



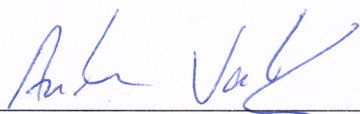
---

Prof<sup>º</sup>. Alvaro José Boareto Mendes, D.Sc.  
**Orientador**



---

Prof<sup>º</sup>. João Crisóstomo de Queiroz Neto, D.Sc.



---

Prof<sup>ª</sup>. Andrea Valdman, D.Sc. DEQ-UFRJ.

**Niterói  
1/2015**

*Toda ação humana, quer se torne positiva ou negativa, precisa  
depende de motivação.*

*Dalai Lama*

## **AGRADECIMENTOS**

Agradeço, primeiramente, a Deus, pela vida.

Aos meus pais Josane Maria de Azevedo Ribeiro Silva e Luiz Carlos da Silva, pela confiança e apoio incondicional no meu crescimento pessoal e intelectual.

Ao meu irmão Raphael Ribeiro Silva, Anna Luiza Ribeiro Soares Carvalho, Izabela Ribeiro Soares e Daniel da Silva, que sempre estiveram presentes, me incentivando a alavancar o sucesso.

Aos meus amigos, pelos grandes momentos compartilhados.

Aos professores da graduação, pelo incentivo na busca do conhecimento, contribuindo para a minha formação.

À orientadora e amiga, D. Sc. Ninoska Isabel Bojorge Ramirez, que desde o começo da iniciação científica confiou a mim a possibilidade do desenvolvimento deste projeto, me orientando e conduzindo com muita dedicação.

Ao co-orientador D. Sc. Álvaro José Boareto Mendes, pela grande contribuição e disponibilidade no desenvolvimento do trabalho.

Com certeza todas essas pessoas tornaram a realização deste trabalho uma tarefa prazerosa.

## RESUMO

Os sistemas de controle automático de processos apresentam grande importância, sendo aplicados em áreas industriais e científicas. Tal importância deve-se a necessidade de utilização de controladores cada vez mais eficazes, que proporcionem o ajuste das variáveis de forma automática, sem necessidade de intervenção humana.

Não obstante, os processos, no geral, apresentam características fortemente não lineares, o que torna a modelagem e equacionamento do sistema mais difícil de ser realizado.

Sendo assim, o descrito trabalho propõe a modelagem do controle de temperatura de uma planta didática – PD3 – através do uso de redes neuronais artificiais.

O treinamento das redes é obtido através de dados experimentais, e ao final, são discutidos os parâmetros e dados estatísticos da rede final, a fim de verificar a viabilidade do seu uso no sistema em estudo, isto é, se a rede neuronal artificial apresentou alta representatividade dos valores obtidos da planta.

***Palavras-Chave:*** controle automático de processos; inteligência artificial; processos subsimbólicos; redes neuronais artificiais; RNA; planta didática PD3.

## ABSTRACT

The automatic process control systems have great importance, being applied in industrial and scientific fields. Such importance is due to the need to use increasingly effective controllers that provide adjustment of the variables automatically, without human intervention.

However, the processes, in general, exhibit highly non linear characteristics, which makes the modeling and equating of the system more difficult to be performed.

Thus, the described work proposes the modeling of the temperature control of a didactic plant - PD3 - through the use of artificial neural networks.

The training of the networks is obtained through experimental data and, at the end, the parameters and statistical data of the final network are discussed in order to check the feasibility of their use in the test system, that is, if the artificial neural network showed high representation of the values of the plant.

***Key-Words:*** *automated control process; artificial intelligent; subsymbolic process; artificial neural networks; ANN; didactic plant PD3.*



# SUMÁRIO

<b>Capítulo 1</b>	<b>INTRODUÇÃO E OBJETIVOS.....</b>	<b>15</b>
1.1	Introdução .....	15
1.2	Objetivos.....	16
1.2.1	Objetivo Geral .....	16
1.2.2	Objetivos Específicos .....	17
1.3	Organização do texto .....	17
<b>Capítulo 2</b>	<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>19</b>
2.1	Controle de Processos .....	19
2.2	Variáveis Significativas de Controle .....	20
2.3	Estratégias Convencionais de Controle Industrial .....	21
2.3.1	Estratégias de Controle por Realimentação (Feedback).....	21
2.3.2	Estratégia de Controle Antecipatório (Feedforward) .....	23
2.3.3	Estratégia de Controle em Cascata .....	24
2.4	Estratégias Avançadas de Controle Industrial .....	26
2.4.1	Controle Robusto.....	26
2.4.2	Controle Adaptativo .....	27
2.4.3	Controle Inteligente .....	28
2.5	Modelagem Matemática de Processos .....	28
2.6	Redes Neurais – Neurônio Biológico .....	30
2.7	Redes Neurais Artificiais .....	31
2.8	Modelagem através de Rede Neuronal Artificial (RNA) .....	33
2.8.1	Arquitetura e Equacionamento dos Modelos Neurais .....	33
2.8.2	Tipos de RNA.....	37
2.8.3	Desenvolvimento das Redes Neurais Artificiais .....	38
<b>Capítulo 3</b>	<b>METODOLOGIA.....</b>	<b>42</b>
3.1	Descrição da planta.....	42
3.1.1	Planta e Equipamentos .....	42

3.1.2 Sistema Supervisório .....	47
3.1.3 Objeto de Estudo .....	48
<b>3.2</b> Coleta de Dados .....	49
<b>3.3</b> Treinamento da RNA.....	51
<b>Capítulo 4 RESULTADOS E DISCUSSÃO .....</b>	<b>55</b>
<b>4.1</b> Obtenção dos Dados Experimentais .....	55
<b>4.2</b> Treinamento da RNA com Todas as Variáveis de Entrada .....	59
4.2.1 Análises de Desempenho.....	60
4.2.2 Dados Preditos pela RNA versus Dados Observados .....	61
4.2.3 Comparação entre os Dados Experimentais e os Dados Preditos .....	62
4.2.4 Análise dos Dados Estatísticos .....	63
4.2.5 Análise de Sensibilidade.....	64
<b>4.3</b> Comparação de desempenho das melhores RNA's .....	65
4.3.1 Análises de Desempenho.....	67
4.3.2 Dados Preditos versus Dados Observado .....	68
4.3.3 Comparação entre os Dados Experimentais e os Dados Preditos .....	69
4.3.4 Análise dos Dados Estatísticos .....	69
4.3.5 Análise de Sensibilidade.....	70
4.3.6 Análise Final.....	70
<b>Capítulo 5 CONCLUSÕES.....</b>	<b>72</b>
<b>5.1</b> Perspectivas e Sugestões para Trabalhos Futuros .....	73
<b>APÊNDICE A - PARÂMETROS DA RNA FINAL.....</b>	<b>77</b>

## LISTA DE ABREVIATURAS E SIGLAS

CLP	Controlador Lógico Programável
FB	Estratégia de controle <i>feedback</i>
FBC	Controle por realimentação
FF	Estratégia de controle <i>feedforward</i>
FFCDYN	Controle antecipatório dinâmico
FFCSS	Controle antecipatório em estado estacionário
FIT-31	Transmissor indicador da vazão de água no tanque de aquecimento
FIT-32	Transmissor indicador da vazão de água no tanque de mistura
FY-31	Conversor de sinal para a válvula de água quente
FY-32	Conversor de sinal para a válvula de água fria
IA	Inteligência Artificial ( <i>Artificial Intelligence</i> ) $\equiv$ AI
LIT-31	Transmissor indicador do nível de água no tanque de aquecimento
MIMO	<i>Multiple-Input and Multiple-Output</i>
MLP	<i>Perceptron</i> de Múltiplas Camadas ( <i>Multilayer Perceptron</i> )
OPE	<i>OLE for Process Control</i>
PD3	Planta Didática 3, da SMAR
PT-100	Sensor de temperatura do tipo termo resistência
RBF	Rede de Função de Base Radial ( <i>Radial Bases Function</i> )
RNA	Rede Neuronal Artificial ( <i>Artificial Neural Network</i> ) $\equiv$ ANN
SANN	<i>Statistica Automated Neural Networks</i>
SCADA	<i>Supervisory Control And Data Acquisition</i>
SP	<i>Setpoint</i>
T-31 D	Temperatura desejada para a água no Tanque-31 (°C)
T-31 MV	Variável manipulada, diretamente ligada à resistência do Tanque-31 (%)
Tanque-30	Tanque reservatório, presente na planta PD3
Tanque-31	Tanque de aquecimento, presente na planta PD3
Tanque-32	Tanque de mistura, presente na planta PD3
TIC-31	Controlador da temperatura do tanque de aquecimento (°C)
TIC-32	Controlador da temperatura do tanque de mistura
T-30	Temperatura do tanque reservatório (°C)
TIT-31	Transmissor indicador da temperatura de água no tanque de aquecimento

TIT-32	Transmissor indicador da temperatura de água no tanque de mistura
TY-31	Corrente para modular a potência de saída do conversor estático (mA)
VC	Variável controlada
VM	Variável manipulada

## LISTA DE SÍMBOLOS

$a$	Entrada líquida de um neurônio
$a_i$	Sinal de entrada do $j^{\text{ésimo}}$ neurônio
$b_j$	Sinal de saída do $j^{\text{ésimo}}$ neurônio
$c_k$	Valor calculado para o neurônio $k$ , na camada de saída
$d_k$	Valor desejado (saída)
$E$	Erro quadrático
$i$	Entrada da sinapse no neurônio
$j$	Neurônio em análise
$Q_{31}$	Vazão volumétrica da malha 31 (L/h)
$w_{ji}$	Peso da conexão de entrada $i$ no neurônio $j$
$x$	Vetor de entrada dos neurônios para a função gaussiana
$x_j$	Total de ativação do $j^{\text{ésimo}}$ neurônio

## LISTA DE SÍMBOLOS GREGOS

$\epsilon_k$	Vetor do erro de saída
$\mu$	Vetor de pesos de entrada para a função gaussiana
$\eta_j$	Constante linear de proporcionalidade do neurônio $j$
$\sigma$	Propagação da RBF
$\theta_j$	Parâmetro externo (“ <i>bias</i> ”)

## LISTA DE FIGURAS

Figura 2.1 - Esquema do controle de temperatura em tanque de mistura. ....	21
Figura 2.2 - Diagrama de blocos da estratégia de controle realimentado.....	22
Figura 2.3 - Diagrama de blocos da estratégia de controle antecipatório (FB – estratégia de controle <i>feedback</i> e FF – estratégia de controle <i>Feedforward</i> ). ....	23
Figura 2.4 - Respostas de alimentação e realimentação para um sistema de mistura. ....	24
Figura 2.5 - Diagrama de blocos da estratégia de controle em cascata. ....	25
Figura 2.6 - Resposta de controle de realimentação e em cascata a uma variação de -25°C na temperatura de alimentação para o aquecedor.....	25
Figura 2.7 - Diagrama de blocos de um sistema de controle robusto.....	26
Figura 2.8 - Diagrama de blocos de um sistema de controle adaptativo direto.....	27
Figura 2.9 - Diagrama de blocos de um sistema de controle adaptativo indireto (ou auto ajustável).....	27
Figura 2.10 - Neurônio biológico. ....	30
Figura 2.11. Conexões entre os neurônios.....	34
Figura 2.12 - Modelo de RNA multicamadas (MLP – <i>Multilayer Perceptron</i> ).....	34
Figura 2.13 Estrutura do $j^{\text{ésimo}}$ neurônio.....	35
Figura 2.14 – Esquema de funcionamento do treinamento com os subconjuntos de dados para treinamento e para teste. ....	41
Figura 3.1 - Planta Didática PD3 da SMAR.....	43
Figura 3.2 - Diagrama P&ID da planta PD3, com indicação do fluxo realizado pela água nos experimentos.....	44
Figura 3.3 – Sinótico da planta PD3.....	48
Figura 3.4 - Dados experimentais trabalhados pela máscara desenvolvida para o sistema. 51	
Figura 3.5 – Estrutura da RNA estudada.....	52
Figura 4.1 - Experimento realizado sem recirculação de água quente no sistema. ....	55
Figura 4.2 - Sequência de dados experimentais da temperatura da água no Tanque-31.....	56
Figura 4.3 - Sequência de dados experimentais da temperatura da água no Tanque-30.....	57
Figura 4.4 - Sequência de dados experimentais das variáveis T-31 MV e TY-31.....	57
Figura 4.5 - Sequência de dados experimentais da vazão no Tanque-31.....	58
Figura 4.6 - Sequência de dados experimentais do nível da água no Tanque-31.....	58
Figura 4.7 – Esquema de entrada e saída utilizado no treinamento da RNA. ....	59
Figura 4.8 - Histograma de distribuição dos resíduos. ....	61

Figura 4.9 - Dados preditos pela RNA vs. dados observados.....	62
Figura 4.10 – Temperatura do Tanque-31 <i>versus</i> sequência de dados: comparação dos dados preditos pela RNA com os dados experimentais. ....	63
Figura 4.11 - Estrutura utilizada no 2º Treinamento da RNA. ....	66
Figura 4.12- Estrutura utilizada no 3º Treinamento da RNA. ....	66
Figura 4.13 – Gráfico de probabilidade para comparação dos dados preditos em cada treinamento <i>versus</i> dados observados.....	68
Figura 4.14 - Temperatura do Tanque-31 <i>versus</i> sequência de dados. Comparação dos dados preditos em cada treinamento com os dados experimentais.....	69

## LISTA DE TABELAS

Tabela 2.1 - Funções de ativação utilizadas para treinamento das redes neurais artificiais, no programa Statistica 12.0. ....	36
Tabela 3.1 - Testes experimentais para representação do sistema e treinamento da RNA. ....	49
Tabela 4.1 - Cinco melhores redes treinadas com seis variáveis de entrada e uma variável de saída. ....	60
Tabela 4.2 - Estatística da regressão para a rede neuronal artificial para a variável de saída (MLP 6-23-1). ....	63
Tabela 4.3 - Análise de sensibilidade do treinamento realizado com seis variáveis de entrada. ....	64
Tabela 4.4 - Cinco melhores redes obtidas no treinamento 2, com cinco variáveis na camada de entrada. ....	67
Tabela 4.5 - Cinco melhores redes obtidas no treinamento 3, com cinco variáveis na camada de entrada. ....	67
Tabela 4.6 - Comparação dos desempenhos das RNA selecionadas em cada treinamento. ....	68
Tabela 4.7 - Dados estatísticos das redes treinadas. ....	70
Tabela 4.8 - Comparação entre as análises de sensibilidade para as três diferentes estruturas de RNA treinadas. ....	70
Tabela A.1 - Pesos e "bias" de cada conexão da rede MLP 6-23-1. ....	77



# Capítulo 1 INTRODUÇÃO E OBJETIVOS

No presente capítulo se pleiteia a necessidade de implementação de estruturas cada vez mais sofisticadas, para a identificação e controle de processos complexos. Devido à característica não linear dos processos operacionais, essas estruturas devem ser capazes de modelar a dinâmica do sistema e controlar as variações ocorridas na região de operação da planta.

Sendo assim, dá-se ênfase no estudo para aplicação de Redes Neuronais Artificiais em um sistema de controle automático de temperatura, conforme descrito nas próximas seções.

## 1.1 Introdução

Segundo Smith e Corripio (2008) os processos são dinâmicos por natureza, havendo a necessidade de realizar o controle de suas variáveis, uma vez que alterações sempre ocorrem. Diversos estudos são propostos a fim de obter sistemas mais ágeis que, conseqüentemente, proporcionem melhorias e reduções de custo (SMITH e CORRIPIO, 2008; SEBORG, EDGAR, *et al.*, 2010; LUYBEN, 1986). A aplicação dos estudos tem sido fortemente utilizada em sistemas industriais, cada vez mais complexos.

Em concordância, Seborg, *et al.* (2010) afirmam que sistemas de controle de processos vêm sendo desenvolvidos para diferentes áreas de atuação, tanto industriais como científicas. O objetivo é tornar o processo produtivo automático, com aumento de confiabilidade e versatilidade, resultando em operações mais simples e econômicas.

Para se implementar a automação de um sistema é necessário ter uma visão global do processo a ser automatizado, associando aos princípios da eletrônica, os sistemas computacionais, as restrições mecânicas das unidades operacionais e os elementos de controle. O sistema de automação é completo quando toda linha de produção funciona do início ao fim sem a intervenção humana, agindo apenas pela ação das próprias máquinas e estratégias de controle. As etapas para desenvolver um controle automático podem ser resumidas da seguinte forma: inicia-se com a modelagem matemática do processo, a partir do qual se analisa o comportamento dinâmico da planta e então se projeta um controlador que fará o sistema evoluir da forma desejada, além de se adaptar às mudanças dos elementos sob controle.

Porém, há três grandes problemas na implementação de sistemas comerciais de controle de processos químicos: o comportamento não linear do processo, restrições físicas das unidades operacionais, dos sensores e elementos de controle, e ainda seus comportamentos dinâmicos. Devido à complexidade de problemas de controle não linear, torna-se necessário, no geral, a aplicação de vários procedimentos computacionais ou emprego de aproximações para a sua solução. Uma série de métodos baseados em redes neuronais artificiais tem sido sugerida para problemas de controle ótimo, onde o objetivo é minimizar uma função objetivo do controle (AHMED, 2014).

De forma a superar as dificuldades no desenvolvimento de modelos fenomenológicos, estão sendo utilizados modelos empíricos baseados em redes neuronais artificiais, tanto para fins de modelagem e otimização de processos, quanto para o projeto de estratégias de controle. Destaca-se que as redes neuronais artificiais (RNA) têm encontrado grande aplicação para a identificação e modelagem de sistemas não lineares. Como um todo, verifica-se também o crescimento das aplicações de RNA, em diversas áreas da ciência e Engenharia, que buscam, através da inteligência artificial, desenvolver sistemas computacionais inteligentes, que simulem o comportamento do cérebro humano ao resolver determinadas tarefas (BAUGHMAN e LIU, 1995).

As RNA são treinadas para cada sistema e são compostas por neurônios estruturados no interior de uma rede e interligados entre si, por onde passam os sinais, com seus respectivos pesos. Estes neurônios atuam independentemente e em forma paralela, o que permite que suas respostas sejam simultâneas. Na sequência, as respostas são combinadas mediante alguma função, para que possa se obter os sinais de saída e modelar matematicamente o sistema (HAYKIN, 2001).

Neste trabalho se propõe a aplicação de redes neuronais artificiais para a modelagem do sistema de controle automático de temperatura de um tanque presente no processo de uma unidade didática da SMAR (PD3 – Planta Didática 3).

## **1.2** Objetivos

### *1.2.1 Objetivo Geral*

O exposto trabalho tem como objetivo aplicar a metodologia de redes neuronais artificiais para representação de sistemas de controle automático de processos, a partir do estudo da dinâmica do sistema.

### 1.2.2 *Objetivos Específicos*

Para atingir o objetivo geral, serão realizados os seguintes objetivos específicos:

- estudar a dinâmica de controle automático de temperatura de um tanque da planta PD3 da SMAR;
- obter dados experimentais do sistema, considerando diferentes cenários;
- treinar redes neurais artificiais empregando os dados experimentais para representação do sistema em estudo;
- avaliar os parâmetros (pesos e “*bias*”) e os dados estatísticos das redes treinadas, para definição da melhor rede.

## 1.3 Organização do texto

Conforme supracitado, a necessidade de implementação de controles avançados de processos, devido à complexidade dos sistemas e forte interação entre as variáveis, motiva o desenvolvimento do presente trabalho. Assim, para facilitar a apresentação das discussões, o documento está dividido em cinco capítulos, conforme abaixo.

Neste Capítulo 1 – Introdução e Objetivos, os estudos foram apresentados e contextualizados. São apresentados também os objetivos e a linha estrutural do trabalho.

No Capítulo 2 – Revisão Bibliográfica, serão apresentados conceitos de controle automático de processos, descritos na literatura, com propostas de aplicação de estratégias de controle fundamentadas em modelos neuronais. Assim, ao longo do capítulo serão explorados conceitos e aplicações das redes neurais artificiais (modelos mais usados em aplicações científicas e tecnológicas), além das vantagens e limitações da ferramenta proposta (RNA).

No Capítulo 3 – Metodologia, será descrita a metodologia da análise experimental adotada no trabalho, utilizando como base de estudo a planta didática (PD3) da SMAR para coleta de dados experimentais e posterior aplicação de RNA através do *software* Statistica® (StatSoft, versão 12.0), a fim de treinar as redes com base no sistema de monitoramento e controle de temperatura.

Logo no Capítulo 4 – Resultados e Discussão, serão apresentados e discutidos os resultados do estudo realizado, visando obter a melhor rede que representasse o sistema em estudo.

Finalmente, no Capítulo 5 – Conclusão, serão apresentadas as conclusões dos resultados obtidos e recomendações para futuras aplicações das redes neuronais artificiais em sistemas de controle.

No Apêndice serão apresentados os parâmetros (pesos e “*bias*”) da rede final, dispostos a partir de tabela.

# Capítulo 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são destacados termos de controle de processos importantes para o estudo em análise. Na sequência do capítulo, descreve-se uma revisão sobre redes neurais artificiais, abrangendo conceituação, propriedades e aplicações industriais, além de descrever alguns algoritmos de treinamento, com objetivo de detalhar a proposta de controle a ser trabalhada nos capítulos subsequentes e argumentar sua motivação.

Salientam-se também os fundamentos e os métodos para a modelagem e treinamento das redes.

## 2.1 Controle de Processos

O estudo de controle automático de processos é de fundamental importância, tendo em vista que os processos são dinâmicos por natureza, resultando em alterações que necessitam ser ajustadas (SMITH e CORRIPIO, 2008).

Esta área apresentou grande evolução ao longo do tempo, conforme será descrito nos próximos tópicos (CPDEE, 2002).

Os primeiros sistemas de controle foram desenvolvidos no final do século 19, a fim de automatizar as linhas de montagem da época. Estes dispositivos foram desenvolvidos para a execução de cada tarefa e apresentavam natureza mecânica.

A partir dos anos 20 os estudos de controle de processos se tornaram mais complexos devido à substituição dos dispositivos mecânicos por relés e contadores.

Em relação ao controle automático de processos químicos, Luyben (1986) destaca que seu uso foi consolidado na década de 60, quando engenheiros químicos adaptaram os estudos já realizados nos campos de aeronáutica e de eletricidade às plantas industriais.

Na sequência, com o desenvolvimento de computadores comerciais para fins de controle por programação, ao início dos anos 70, foi realizada a comparação destes sistemas com as interligações elétricas. Durante este período, desenvolveu-se também o Controlador Lógico Programável (CLP), para suprir a indústria automobilística norte-americana. Este controlador é disposto ao longo das linhas do processo.

Atualmente, o sistema de supervisão e controle mais utilizado em indústrias é o SCADA (*Supervisory Control And Data Acquisition*), com monitores automatizados, ligados ao processo, que proporcionam agilidade na correção de desvios.

O controle automático de processos é utilizado em quase todas as plantas industriais, desde as mais simples até as mais complexas, sendo de importante destaque para controlar as variáveis do processo, trazendo como benefícios, produtos finais com altas qualidades e processos mais seguros.

## 2.2 Variáveis Significativas de Controle

Para o desenvolvimento de sistemas de controle de processos é necessário compreender a classificação das variáveis significativas.

De começo, as variáveis são separadas pela sua contribuição no processo. Neste caso, existem as variáveis de entrada (*inputs*) e as variáveis de saída (*outputs*).

Para o projeto e a análise de sistemas de controle, é conveniente dividir as variáveis de entrada em variáveis manipuladas (VM), que são ajustadas para manter o sistema conforme desejado, e variáveis de perturbação, que são determinadas pelo ambiente externo (SEBORG, EDGAR, *et al.*, 2010). Enquanto que as variáveis de saída se referem às variáveis de processo (ou variáveis controladas, VC), relacionadas ao fluxo de saída ou condições dentro de uma unidade operacional.

Segundo Smith e Corripio (2008) o objetivo do controle de processos é manter a variável controlada em um determinado valor desejado (*setpoint*, SP), independente das perturbações ocorridas no sistema (distúrbios).

O sistema de controle pode estar sendo operado de forma manual (o controlador está desconectado do sistema, e para isso é necessário que o operador efetue as alterações na variável manipulada) ou de forma automática (o controlador realiza a análise das variáveis e envia a ação à variável manipulada).

Conforme sugerido por Seborg, *et al.* (2010), na sua forma ideal, um sistema de controle deve satisfazer os critérios de desempenho, tais como: a malha fechada do processo tem que ser estável; os efeitos de perturbações devem ser minimizados; as respostas para mudanças de *setpoint* devem ser rápidas; as ações de controle excessivas devem ser evitadas; o sistema deve ser robusto em relação a erros de modelagem e alterações nas condições de processo.

## 2.3 Estratégias Convencionais de Controle Industrial

Existem diversas estratégias de controle indicadas na literatura. As mesmas são aplicadas a fim de obter um sistema com controle adequado das variáveis.

Nas próximas seções serão apresentados os tipos de estratégias mais comumente utilizados nas indústrias de processos, química e bioquímica.

### 2.3.1 Estratégias de Controle por Realimentação (Feedback)

O controle automático de processos por realimentação consiste basicamente em uma operação de “tentativa e erro”, no qual tem como objetivo, manter a variável controlada no ponto desejado (*setpoint*, SP).

A partir de uma malha fechada, a alteração efetuada pelo sistema de controle é monitorada de forma dinâmica, minimizando os erros em regime estacionário.

Smith e Corripio (2008) descrevem esta malha de controle como a mais utilizada nas indústrias de processo, devido à simplicidade e por atender aos requisitos de segurança, qualidade do produto e razão de produção.

Não obstante, estes autores ressaltam também que este sistema trabalha com correção dos dados finais, sendo necessário que o distúrbio efetuado ao início se propague por todo o sistema, para que então o controlador possa dar prosseguimento à correção. Assim, esta estratégia de controle pode não ser vantajosa, dependendo da necessidade do tempo de resposta do sistema. Para entendimento desta estratégia de controle, segue a Figura 2.1, como exemplo.




Figura 2.1 - Esquema do controle de temperatura em tanque de mistura.  
Fonte: Bojorge Ramírez (2012).

O esquema refere-se ao controle automático da temperatura de um tanque de mistura. Inicialmente a temperatura do sistema é medida através de um sensor em contato com o processo (Etapa 1). Para este exemplo, pode-se destacar os seguintes dispositivos para desempenho desta função: termopar, termo resistência, *termistor*, etc.

Na seqüência, o sinal gerado pelo sensor é enviado a um transmissor, que o converte em um sinal padrão e transmite ao controlador (Etapa 2). Em geral, o transmissor encontra-se fisicamente acoplado ao sensor. Este par é denominado Transdutor.

No controlador (Etapa 3), o sinal é analisado e comparado com o valor desejado (neste exemplo, a temperatura). Esta comparação é feita pela diferença entre os valores, sendo denominada erro.

Ao final, a partir do valor encontrado para o erro, o controlador envia um sinal para o elemento final de controle, ou atuador (neste caso, válvula de entrada de vapor), para correção da temperatura (Etapa 4).

No exemplo abordado, para cada alteração efetuada pelo atuador é realizada uma nova comparação dos dados reais com os desejados, uma vez que esta alteração deverá afetar a nova medição do sensor (estratégia de *feedback*).

A Figura 2.2 apresenta o diagrama de blocos da estratégia de controle *feedback*.

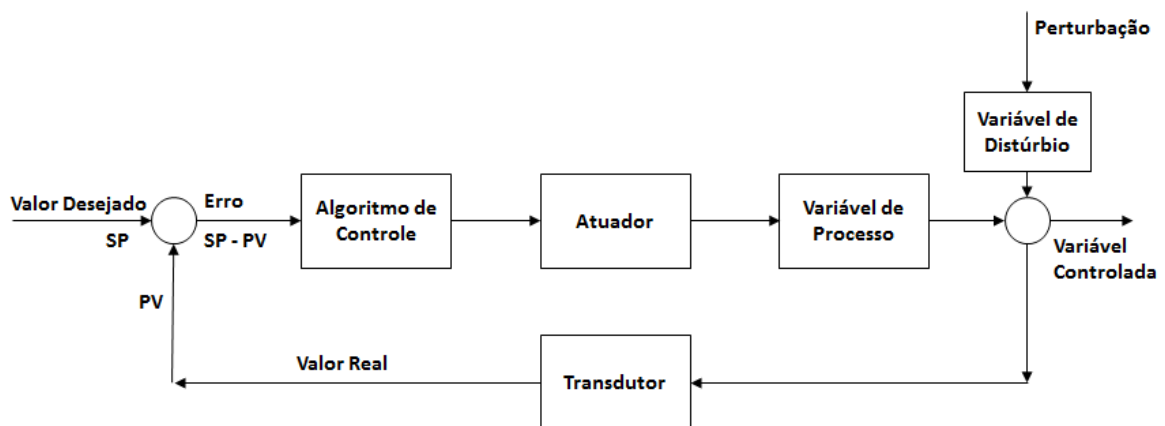


Figura 2.2 - Diagrama de blocos da estratégia de controle realimentado.

Tendo em vista que a estratégia de controle por realimentação necessita que o distúrbio se propague ao longo do sistema, para que então o controlador possa atuar, o sistema trabalha com desvios temporários. Porém, Smith e Corripio (2008) destacam que apesar de muitos processos permitirem este desvio, em muitos outros o desvio precisa ser minimizado. Para isto, existe a possibilidade de implementação de outras estratégias de controle, que auxiliem o



controle por realimentação (como por exemplo o controle antecipatório e o controle em cascata, descritos nas próximas seções).

Cabe ressaltar que em todas as estratégias de controle as seguintes ações são realizadas (SMITH e CORRIPIO, 2008):

- Medição da variável controlada;
- Decisão, com base na diferença entre o valor desejado e o valor obtido na medição;
- Ação, a fim de minimizar o erro calculado no item anterior.

É importante destacar também que a planta em estudo (PD3), da SMAR, realiza o controle automatizado das variáveis pressão, vazão e temperatura, utilizando as três malhas de controle citadas no texto (antecipatório, realimentação negativa e em cascata).

### 2.3.2 Estratégia de Controle Antecipatório (*Feedforward*)

A estratégia de controle antecipatório (*feedforward*) refere-se a forma de compensação dos distúrbios antes dos mesmos afetarem a variável controlada. Para isso, é necessário conhecer as características do estado estacionário e da dinâmica do processo.

A Figura 2.3 apresenta o diagrama de blocos da estratégia de controle antecipatório.

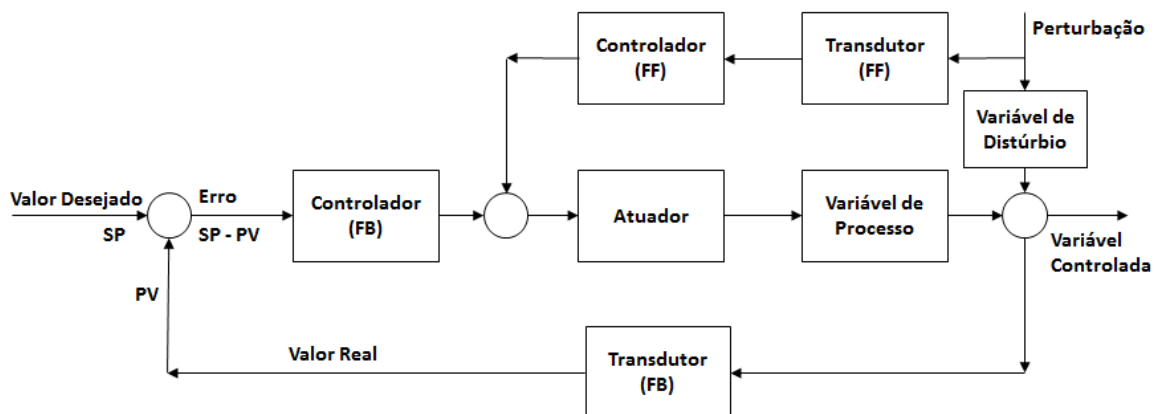


Figura 2.3 - Diagrama de blocos da estratégia de controle antecipatório (FB – estratégia de controle *feedback* e FF – estratégia de controle *Feedforward*).

Smith e Corripio (2008) definem esta forma de controle como sendo uma estratégia “proativa”, pois caso as medições ocorram de forma eficaz e a ação de ajuste for realizada

corretamente, a variável controlada poderá não ser afetada, permanecendo próxima ao ponto fixo (valor desejado).

A Figura 2.4 demonstra, como exemplo, a comparação entre as estratégias de controle por realimentação (FBC) e antecipatório (estado estacionário: FFCSS; dinâmico: FFCDYN) utilizados em um processo de mistura (SMITH e CORRIPIO, 2008).




Figura 2.4 - Respostas de alimentação e realimentação para um sistema de mistura.

Fonte: Smith e Corripio (2008).

Pode-se verificar que, para este exemplo, o uso do controle *feedforward* apresentou uma resposta consideravelmente mais rápida que o controle *feedback*.

Porém, é importante destacar que a implementação e a operação do controle antecipatório necessitam de uma quantidade significativa de engenharia e treinamento (SMITH e CORRIPIO, 2008), e portanto não é muito utilizada, ao se comparar com o controle de realimentação (mais simples).

### 2.3.3 Estratégia de Controle em Cascata

O controle em cascata consiste no uso de duas ou mais malhas de controle por realimentação, que afetam umas às outras. O uso mais comum refere-se ao de duas malhas (malha primária e secundária), sendo que a malha secundária é determinada como sendo aquela que responderá mais rapidamente às variações do distúrbio, tendo em vista que a mesma está ligada diretamente ao atuador (SMITH e CORRIPIO, 2008).

Esta estratégia de controle é utilizada quando ocorrem muitas perturbações no sistema, sendo necessário que haja uma monitoração mais rigorosa.

A Figura 2.5 apresenta o diagrama de blocos para a estratégia de controle em cascata.

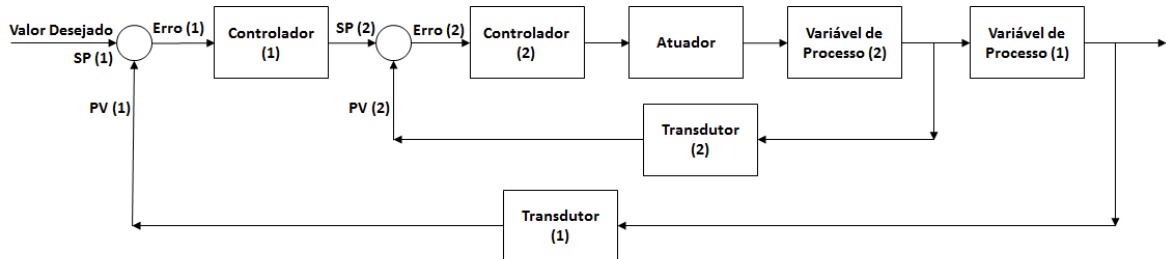


Figura 2.5 - Diagrama de blocos da estratégia de controle em cascata.

Smith e Corripio (2008) compararam as respostas dos controles de realimentação e em cascata para um processo no qual houve a variação de  $-25^{\circ}\text{C}$  da temperatura de entrada do reagente (*vide* Figura 2.6).

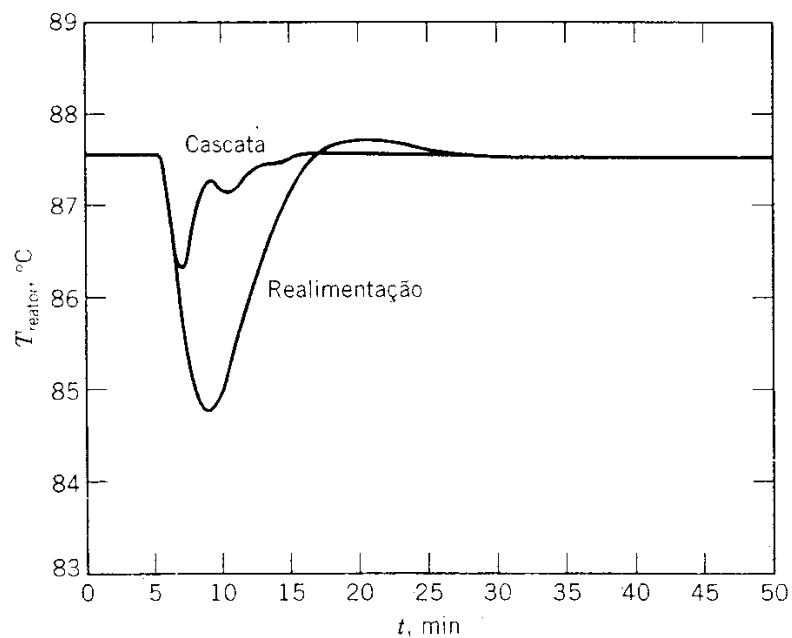


Figura 2.6 - Resposta de controle de realimentação e em cascata a uma variação de  $-25^{\circ}\text{C}$  na temperatura de alimentação para o aquecedor.

Fonte: Smith e Corripio (2008).

Verifica-se que o controle em cascata apresentou reposta mais rápida que o controle por realimentação. Porém, igualmente ao controle antecipatório, o controle em cascata é mais complexo e, portanto, é utilizado apenas quando necessário.

## 2.4 Estratégias Avançadas de Controle Industrial

Segundo Seborg, *et al.* (2010) o aumento da complexidade de alguns processos gerou a necessidade de implementação de sistemas de controles industriais mais eficientes. Esta complexidade relatada ocorre, principalmente, devido aos sistemas com perfis não lineares, que acarretam em resultados não satisfatórios para o uso de controles convencionais.

Sendo assim, foram desenvolvidas estratégias avançadas de controle, conforme apresentado nas próximas seções.

### 2.4.1 Controle Robusto

Luque (2007) classifica o controle robusto como uma estratégia de controle desenvolvida para atuar, garantindo a estabilidade e atendimento ótimo, apesar de incertezas presentes na representação do modelo da planta. Este método (presente no ramo de pesquisa desde o final dos anos 70) realiza ações de controle *feedback*, tendo em vista sistemas MIMO (“*Multiple Inputs and Multiple Output*”), com múltiplas entradas e saídas.

Segundo Trofino (2000) esta forma de controle também minimiza os efeitos de perturbações externas, como por exemplo, ruídos e mudanças de temperatura.

A Figura 2.7 apresenta o diagrama de blocos deste modelo.

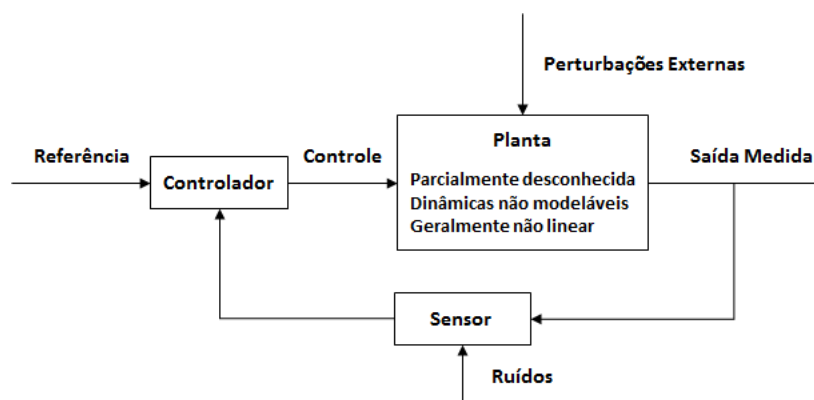


Figura 2.7 - Diagrama de blocos de um sistema de controle robusto.

## 2.4.2 Controle Adaptativo

Para sistemas com variações frequentes e significativas das condições do processo, Seborg, *et al.* (2010) consideram como vantagem a implementação do controle adaptativo.

Esta estratégia foi introduzida na literatura no final dos anos 50 e consiste no ajuste automático dos parâmetros de controle, a fim de compensar as variações do processo.

Segundo Lages (2007) o controle adaptativo apresenta duas abordagens: direta, cujos parâmetros do controlador são ajustados diretamente em função da saída do processo (*vide* Figura 2.8) e indireta (ou auto ajustável), que considera que os parâmetros do processo sejam conhecidos, assim, o ajuste do controlador é realizado a partir do cálculo entre os parâmetros estimados e os conhecidos (*vide* Figura 2.9).

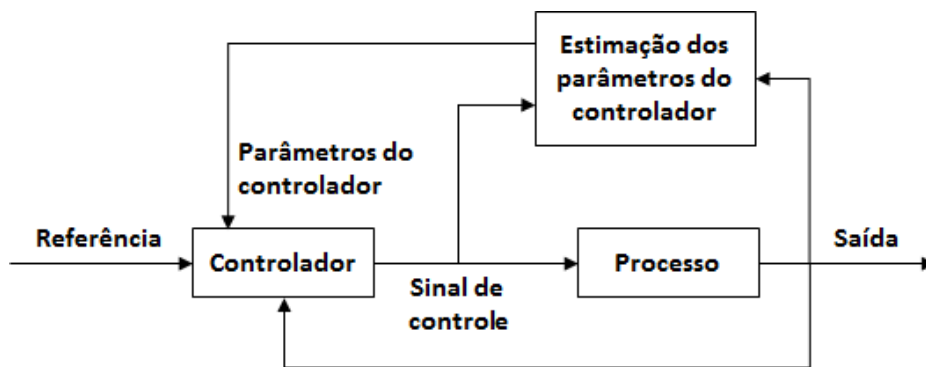


Figura 2.8 - Diagrama de blocos de um sistema de controle adaptativo direto.

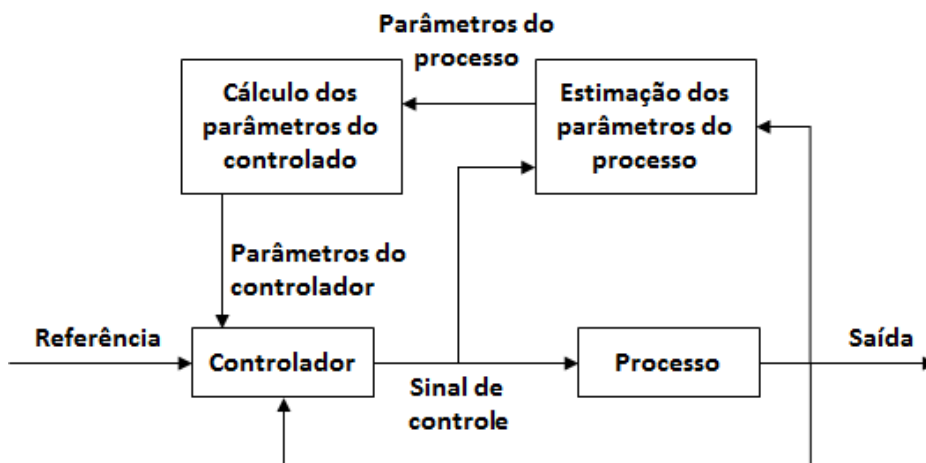


Figura 2.9 - Diagrama de blocos de um sistema de controle adaptativo indireto (ou auto ajustável).

### 2.4.3 Controle Inteligente

Segundo De Araújo (2004) o controle inteligente foi desenvolvido para a atuação em sistemas que não apresentam modelos matemáticos bem conhecidos e/ ou cuja aplicação requer o uso de controladores com representações diferentes da lógica clássica.

Este método deve ser capaz de realizar o aprendizado de forma automática, elaborar o planejamento do controle através da classificação das informações que caracterizam o sistema, e apresentar mecanismo de tomada de decisão.

Como exemplo desta estratégia de controle pode-se destacar a lógica *Fuzzy* (ou nebulosa) e as redes neuronais artificiais (DE ARAÚJO, 2004).

Seborg, *et al.* (2010) descrevem a lógica *Fuzzy* como uma técnica de controle *feedback* que utiliza dados qualitativos, ao invés de dados quantitativos, dispostos através de regras. Caneppele e Seraphim (2010) exemplificam o uso desta técnica em seu estudo para simulação de um controle inteligente em um sistema híbrido de geração de energia elétrica, utilizando as energias solar-fotovoltaica e eólica. Neste estudo foi verificado que a lógica *Fuzzy* possibilitou o controle e gerenciamento do sistema, pois possibilitava a modelagem e manipulação de dados naturais à linguagem humana, através da estipulação de regras.

Em contraste, as redes neuronais artificiais, conforme descrito previamente neste trabalho, constituem um modelo empírico para modelagem de sistemas não lineares, que utilizam como base dados quantitativos para treinamento. Além de descrever a dinâmica do processo estudado, a RNA pode ser utilizada como sensor em sistemas de detecção de falha e diagnóstico e como componente auxiliar à estratégia de controle adaptativo, a partir da previsão de comportamentos do sistema, devido ao modelo empírico desenvolvido (DE ARAÚJO, 2004).

## 2.5 Modelagem Matemática de Processos

A modelagem matemática de um processo consiste na obtenção da equação característica do sistema (SMITH e CORRIPIO, 2008).

Usualmente os modelos são determinados através da realização de balanços de massa e balanços de energia para o objeto em estudo. Neste contexto, quanto mais variáveis existirem no sistema, mais complexo será o modelo matemático a ser desenvolvido. Além disso, quando o sistema possui uma grande quantidade de variáveis, pode levar a dependência paramétrica em função da redução do número de graus de liberdade. Isso torna mais complexa a solução

do sistema utilizando métodos clássicos, sendo necessário buscar modelos computacionais, como por exemplo, as redes neurais artificiais, que modelam o sistema pela identificação das dinâmicas das relações entre seus dados experimentais (DE ARAÚJO, 2004). É importante destacar que a modelagem matemática do sistema é de fundamental importância para definir e implementar estratégias de controles.

Não obstante, a maioria dos processos químicos apresentam fatores que dificultam a modelagem, devido às características como não linearidade, presença de tempo morto e existência de parâmetros que variam com o tempo. Aliado a essas dificuldades intrínsecas ao processo tem-se, ainda, os critérios econômicos da produção de determinado produto com menor custo e elevada qualidade. Esses fatores têm contribuído para que as indústrias optem por novas estratégias de controle, tal como o controle preditivo e o controle adaptativo, pois controladores convencionais a parâmetros constantes, apresentam desempenho limitado (FERRARI, 2010). Seborg, *et al.* (2010) ressaltam que o controle preditivo baseia-se na determinação das sequências adotadas pela estratégia de controle durante a medição dos valores reais para a predição dos valores futuros de saída.

Na maioria dos processos industriais o uso dos procedimentos de projeto de controladores preditivos apresentam dificuldades, pois dependem da modelagem matemática do processo que, em muitos casos, não é simples ou apresenta problemas no quesito da incorporação de dados disponíveis, a partir do conhecimento de especialistas. Nestes casos, técnicas de identificação baseadas em redes neurais artificiais têm sido aplicadas. Por causa da habilidade de aproximar funções complexas, a RNA tem sido explorada como modelo de processos químicos (HAYKIN, 2001). A vantagem principal deste modelo é que pode ser sintetizado sem conhecimento detalhado do processo em questão, atuando apenas após a apresentação de informações características do processo em particular. Esta propriedade é comum a uma grande classe de modelos funcionais, conhecidos como modelos não-paramétricos, que incluem RNA e série de Fourier, por exemplo. Porém, a grande dificuldade da utilização de uma RNA é devido à necessidade de um conjunto relativamente grande de dados de entrada/saída do processo, para seu treinamento, que nem sempre estão disponíveis ou passíveis de obtenção.

RNA têm sido aplicadas a um número crescente de problemas do mundo real de considerável complexidade. Sua vantagem mais importante é na resolução de problemas que não têm uma solução algorítmica ou para os quais a solução algorítmica é demasiadamente complexa para ser determinada. Assim a RNA é capaz de aprender e generalizar a partir de

alguns exemplos específicos, reconhecendo os padrões e características do sinal mesmo na presença de ruído (BAUGHMAN e LIU, 1995).

Dado que o escopo deste trabalho finda o uso de redes neuronais artificiais em sistemas de controle automático de processos, as próximas seções têm como objetivo abordar os conceitos desta área (RNA).

## 2.6 Redes Neuronais – Neurônio Biológico

O cérebro humano é considerado como um dos mais complexos processadores, sendo constituído de aproximadamente 10 bilhões de neurônios, responsáveis pelo processamento das funções e movimentações do organismo (HAYKIN, 2001).

O neurônio biológico é composto pelas seguintes seções (*vide* Figura 2.10): corpo celular; dendritos; axônio e suas terminações. Segundo Haykin (2001), os dendritos recebem as informações de entrada (ou estímulos) de outros neurônios, através de impulsos nervosos, e conduzem essas informações até o corpo celular. Nesta etapa a informação é processada e um segundo impulso (com a ação) flui do corpo celular para o axônio. Caso este esteja conectado com outro neurônio, a informação será repassada.

Ressalta-se que os locais de contato entre os neurônios são denominados de sinapse, enquanto que o conjunto total dos neurônios é classificado como rede neuronal.




Figura 2.10 - Neurônio biológico.

Fonte: StatSoft (2015).

Sendo assim, pesquisadores apresentaram interesse em simular o comportamento das redes biológicas a fim de utilizá-las na modelagem de sistemas complexos. Deste modo foi desenvolvido o conceito de redes neuronais artificiais, conforme descrito nas próximas seções.



## 2.7 Redes Neurais Artificiais

As redes neuronais artificiais (RNA), também conhecidas como “redes neurais”, resultaram de estudos sobre inteligência artificial (IA). Segundo Barr e Feigenbaum (1981), o objetivo da IA é desenvolver sistemas computacionais inteligentes, que simulem o comportamento do cérebro humano ao resolver determinadas tarefas. Pode-se destacar as seguintes tecnologias como as principais no ramo da IA: sistemas especialistas, sistemas de lógica “*Fuzzy*” e redes neuronais artificiais (VERDUIN, 1995; CROWE e VASSILIADIS, 1995 *apud* BAUGHMAN e LIU, 1995).

Os sistemas especialistas realizam processamentos macroscópicos e simbólicos, através de dados não numéricos (ou nomes). Já os sistemas de lógica “*Fuzzy*” objetivam a quantificação de sistemas baseados em regras, isto é, apresentam como raciocínio a utilização de representações qualitativas aproximadas em quantitativas. Por outro lado, as redes neuronais artificiais realizam processamentos subsimbólicos, caracterizados por iterações microscópicas que eventualmente se manifestam como macroscópicas (BAUGHMAN e LIU, 1995).

Em concordância, Haykin (2001) define RNA como uma “máquina” projetada para modelar a forma na qual o cérebro humano trabalha, sendo estruturada a partir de unidades de processamento (neurônios) maciços, paralelamente distribuídos na rede. A aprendizagem da rede é feita pelos neurônios, que são capazes de processar os sinais.

Uma característica marcante da RNA é a sua total independência da natureza fenomenológica do processo a ser abordado (modelo “caixa preta”), de modo que tal abordagem torna-se interessante quando as relações entre as variáveis de um determinado fenômeno são muito complexas (BENITEZ, CASTRO e REQUENA, 1997).

Neste contexto, Haykin (2001) aponta os seguintes benefícios das redes neuronais artificiais: não linearidade; mapeamento de entrada e saída; adaptabilidade; uniformidade de análise e projeto; analogia neurobiológica, dentre outros.

Em complemento, Baughman e Liu (1995) apresentam como vantagens das RNA: informação distribuída através dos neurônios; habilidade de aprendizado; melhor adequação para o processamento de dados ruidosos, incompletos ou inconsistentes.

Baughman e Liu (1995) destacam também as seguintes limitações do uso de redes neuronais artificiais: longos tempos de treinamento; necessidade de grande quantidade de dados para treinamento da RNA; sem garantia de resultados ótimos; sem garantia de 100% de confiabilidade.

Apesar das limitações acima, o uso de RNA tem apresentado grande destaque em diversas áreas, tais como, ciências e engenharias, uma vez que consegue resolver problemas cujas soluções analíticas não são possíveis (BAUGHMAN e LIU, 1995).

Ribeiro (2013) avaliou em seu trabalho a qualidade de imagens emitidas por satélites, em duas áreas diferentes no Paraná, através de método de classificação por redes neurais artificiais. As redes foram treinadas a partir de método quantitativo e proporcionaram adequação ao estudo, tendo em vista que ao simular as atividades humanas apresentaram objetividade e agilidade.

Boareto Mendes (2005) destacou em seu trabalho a importância do desenvolvimento de modelos matemáticos com alta representação para o comportamento de processos fermentativos. Assim, partindo de um modelo proposto anteriormente na literatura para a representação da produção de lipase por *Candida rugosa*, Boareto Mendes (2005) estudou o desenvolvimento de um modelo híbrido-neuronal/fenomenológico que representasse o processo com eficiência, uma vez que o anterior apresentou baixa representação para a atividade lipolítica. Ao final do estudo constatou que o novo modelo, utilizando rede neuronal artificial, obteve alta eficiência e adequação ao processo em estudo.

Em similaridade Rosa e Luz (2012) destacaram em seu trabalho a importância do uso de métodos matemáticos para a simulação de processos químicos, tendo em vista a simplicidade para alterar os dados, sem a necessidade de modificar as variáveis durante o processo, muitas vezes difícil. O artigo em questão teve como objetivo simular o processo de moagem seletiva de mesclas binárias através do uso de redes neurais artificiais, observando as proporções dos componentes e o tempo de processamento. Embora tenham apontado que a maioria dos trabalhos da literatura utilizam modelos de balanço populacional, os autores utilizaram as RNA na busca da simplificação e da otimização do processo.

Linhares, Júnior e Araújo (2007) estudaram a aplicação da RNA para identificar a fração molar de pentano na composição do GLP, a partir de variáveis secundárias da planta. Tendo em vista o processo de separação do GLP da gasolina natural, através de uma debutanizadora simulada, os autores destacaram a importância do controle de qualidade do GLP, uma vez que durante a separação, parte de pentanos podem contaminar o gás. Neste caso o uso das redes neurais artificiais teve como objetivo, também, apresentar soluções alternativas ao uso de cromatógrafos para a identificação da fração molar, devido aos longos tempos de medição e altos custos.

Andrade, *et al.* (2010) descreveram em seu trabalho o uso de redes neuronais artificiais para modelar o processo de produção de ácido succínico por via fermentativa, utilizando a cepa *Actinobacillus succinogenes*. A pesquisa teve como objetivo, testar o uso de matérias-primas renováveis para obtenção do ácido, pois o processo de síntese química atual consiste na utilização de produtos não renováveis, caros e poluentes.

Ferrari (2010) desenvolveu em seu trabalho a sintonia dos controladores de nível de uma planta com três tanques acoplados. Para isso, o autor comparou os métodos tradicionais de sintonia de controladores (Ziegler-Nichols) com o método de redes neuronais artificiais e verificou que apesar da sintonia pela RNA apresentar respostas mais lentas, seu desempenho foi superior aos métodos tradicionais.

## **2.8 Modelagem através de Rede Neuronal Artificial (RNA)**

Conforme citado anteriormente, a RNA é composta por neurônios, capazes de processar os sinais, sendo que estes são enviados com pesos.

Segundo Haykin (2001), uma vez que a rede esteja desenvolvida, o processo de aprendizagem deverá ocorrer a partir dos ajustes dos pesos sinápticos, referentes aos sinais de entrada e saída dos neurônios.

Assim, nas próximas seções serão descritas as informações necessárias para a modelagem de redes neuronais artificiais, tais como, sua arquitetura e métodos de treinamento.

### ***2.8.1 Arquitetura e Equacionamento dos Modelos Neurais***

As redes neuronais artificiais são compostas por neurônios, interconectados entre si através de uma rede. Baughman e Liu (1995) apontam a existência de três possíveis conexões (*vide* Figura 2.11): conexão na mesma camada, conexão entre camadas e conexão recorrente.

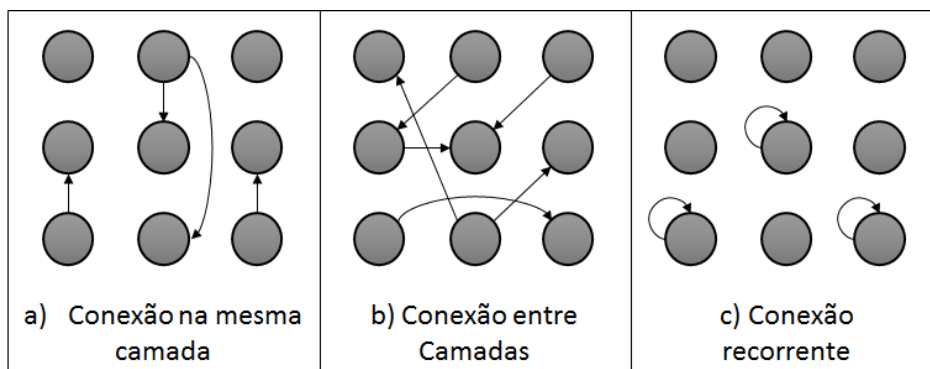


Figura 2.11. Conexões entre os neurônios.

É importante destacar que a conexão entre camadas é a mais utilizada, sendo dividida em “*feedforward*” e “*feedback*”, cujas aplicações são, respectivamente, treinar a RNA para determinar a saída através dos sinais de entrada e desenvolver a RNA para treinar a si própria (BAUGHMAN e LIU, 1995).

A Figura 2.12 demonstra a estrutura mais utilizada para descrever o modelo de redes neuronais artificiais: uma camada de entrada, uma camada escondida e uma camada de saída, interligadas através de uma conexão “*feedforward*”.




Figura 2.12 - Modelo de RNA multicamadas (MLP – *Multilayer Perceptron*).

Através desta estrutura, a camada de entrada recebe uma informação externa e envia, através da rede, para a camada escondida. Nesta camada é desenvolvida a análise e resolução do problema, sem a disponibilização dos passos (etapa onde a maior parte do processamento é realizada). Na sequência, a informação final é repassada à camada de saída, que envia o resultado ao meio externo (BAUGHMAN e LIU, 1995).

Para fins de modelagem de redes neuronais artificiais, Haykin (2001) define o neurônio individual como uma unidade de processamento de informação, com fundamental importância para o estudo de RNA, fazendo-se necessário conhecer o seu modelo. A Figura 2.13 apresenta a estrutura do  $j^{\text{ésimo}}$  neurônio.




Figura 2.13 Estrutura do  $j^{\text{ésimo}}$  neurônio.

Este modelo é constituído por sinais de entrada ( $a_i$ ), dispostos através de vetores, que são multiplicados por seus respectivos pesos individuais ( $w_{ji}$ ), considerando-se  $i$  como a entrada da sinapse no neurônio  $j$ . Os índices multiplicados seguem para um somador que representa o total de ativação de um neurônio ( $x_j$ ), no qual inclui-se o parâmetro externo  $\theta_j$  (*bias*), cujo efeito é de aumentar ou diminuir a entrada líquida da função de ativação. Na sequência é realizada uma função de ativação,  $f(x_j)$ , cuja saída é representada por  $b_j$ .

Em termos matemáticos, a ativação do neurônio pode ser descrita na Equação 2.1:

$$\text{Total de ativação} = x_j = \sum_{i=1}^n (w_{ji} \cdot a_i) - \theta_j \quad (2.1)$$

E a função de transferência na Equação 2.2:

$$f(x_j) = f(w_{ji} \cdot a_i - \theta_j) = f\left(\sum_{i=1}^n (w_{ji} \cdot a_i) - \theta_j\right) \quad (2.2)$$

Para determinar a forma de  $f(x_j)$ , pode-se utilizar diversas funções. Neste trabalho foram consideradas as funções disponíveis no programa utilizado para o treinamento da RNA (*vide* Tabela 2.1).

Tabela 2.1 - Funções de ativação utilizadas para treinamento das redes neuronais artificiais, no programa Statistica 12.0.

<b>Função</b>	<b>Equação</b>	<b>Range</b>
Identidade	$a$	$(-\infty, +\infty)$
Logística	$\frac{1}{1+e^{-a}}$	$(0,1)$
Tangente Hiperbólica	$\frac{e^a - e^{-a}}{e^a + e^{-a}}$	$(-1,+1)$
Exponencial	$e^{-a}$	$(0,+\infty)$
Seno	$sen(a)$	$(0,1)$
Softmax	$\frac{\exp(a_j)}{\sum \exp(a_j)}$	$(0,1)$
Gaussiana	$\frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right]$	

Onde “a” refere-se à entrada líquida de um neurônio (no caso da MLP a soma ponderada dos neurônios). Para a função gaussiana, “x” representa o vetor de entrada dos neurônios, “ $\mu$ ” o vetor de pesos de entrada e “ $\sigma$ ” a propagação das Rede de Função de Base Radial (RBF, abordada na seção 2.3.2).

É importante destacar que as redes neuronais artificiais operam conforme “ajuste de reta” e podem ser substituídas por modelos empíricos matemáticos, dependendo da sua aplicação. A RNA possui melhor capacidade de filtro e trabalha com informações paralelas, divididas entre os nós. Assim, não apresenta grande dependência em um nó, como por exemplo, outros modelos empíricos apresentam para as variáveis independentes (BAUGHMAN & LIU, 1995).

Em relação às demais vantagens do uso de RNA em comparação com outros modelos empíricos, Baughman e Liu (1995) ressaltam também a capacidade adaptativa com possibilidade de ajustes através de novos treinamentos e melhor reconhecimento de padrões, devido ao sistema MIMO (“*Multiple-Input and Multiple-Output*” – entradas e saídas múltiplas).

### 2.8.2 Tipos de RNA

Existe uma variedade de tipos de redes neuronais artificiais estudados atualmente, desde os mais simples até os mais complexos. A seguir são demonstrados os modelos mais utilizados na literatura:

- *Perceptrons* de Camada Única: forma mais simples de uma RNA, para o qual foi desenvolvido o primeiro algoritmo de treinamento. Segundo Haykin (2001) este modelo é utilizado para a classificação de padrões “linearmente separáveis” (padrões que se encontram em lados opostos de um hiperplano).
- *Perceptrons* de Múltiplas Camadas (*Multilayer Perceptron*, MLP): tipo de RNA mais comumente utilizado, concentrando-se em redes do tipo *feedforward*, com algoritmo *backpropagation*.
- Redes de Função de Base Radial (RBF): tipo de RNA bastante utilizado, após a MLP, apresentando como principal diferença a forma de treinamento. Enquanto na MLP o treinamento ocorre em um estágio, a RBF é treinada em dois estágios (no primeiro ocorre a modelagem da distribuição de probabilidade dos dados de entrada, enquanto que no segundo o aprendizado do par entrada-saída fornecido). Outro fator de diferença é que na RBF os “*bias*” são somados apenas aos neurônios da camada de saída.

Segundo StatSoft (2015) a RBF proporciona, geralmente, erros menores e uma convergência mais rápida que as redes MLP, porém esta última rede apresenta capacidade de generalização superior.

Haykin (2001) complementa que a RBF projeta a RNA a partir da aproximação no ajuste de curva em um espaço de alta dimensionalidade. Isto é, verificou-se que processos de classificação de padrões dispostos em um espaço com alta dimensão apresentam maiores probabilidades de serem linearmente separáveis, do que se estivessem em baixas dimensões. Assim, a dimensão da RBF normalmente é mais alta que de uma MLP, sendo que este fator é ajustado no aumento do número de neurônios na camada escondida, o que resulta no aumento de parâmetros do sistema (pesos e “*bias*”).

### 2.8.3 Desenvolvimento das Redes Neurais Artificiais

Para o desenvolvimento da RNA deve-se primeiramente realizar a coleta dos dados experimentais, separando-os em dois conjuntos, sendo um para treinamento e outro para teste. Esta etapa é de fundamental importância e irá definir o desempenho da rede.

A partir dos conjuntos determinados ocorre o treinamento das redes. Para isto faz-se necessário estabelecer o processo de aprendizagem das redes neuronais artificiais. Este processo é classificado conforme relacionamento da RNA com o ambiente (STATSOFT, 2015):

- Aprendizado supervisionado: apresenta em sua estrutura um “professor” ou “instrutor” que correlaciona os dados de saída da RNA com a saída desejada (resultado previamente conhecido) e realiza ajustes nos pesos entre os neurônios, a fim de minimizar os erros até um critério aceitável.
- Aprendizado não supervisionado: neste processo de aprendizagem não existe uma saída conhecida para comparação. Os ajustes dos pesos entre os neurônios são realizados automaticamente através de classificações dos padrões de entrada, em grupos.

Após definido o método de aprendizado ocorre o treinamento da rede a partir da apresentação dos dados selecionados de entrada, com suas respectivas saídas, para que a RNA possa aprender com este par e assim realizar os ajustes dos pesos entre as conexões para obter resultados próximos ao real.

É importante destacar que o algoritmo mais utilizado atualmente para ensino da rede é o *backpropagation*, que consiste em um aprendizado supervisionado, isto é, a partir dos erros calculados entre os valores de saída das redes neuronais artificiais com o valor desejado, este algoritmo realiza o ajuste dos pesos entre as camadas através da retropropagação do erro encontrado, para cada iteração (HAYKIN, 2001).

O objetivo do treinamento por retropropagação é ajustar os pesos e “*bias*” da rede, modificando-os até que a aplicação de um conjunto de entradas produza a saída da rede que corresponda às saídas desejadas ou alvos. Para isso, apresentam-se muitos exemplos de dados históricos à RNA. Treinar a rede, neste caso, corresponde a minimizar a função objetivo não linear que dá o erro entre as saídas “*s*” – preditas pela rede – e as saídas alvos “*t*” para  $N_p$  padrões em função dos pesos e “*bias*”, que são as variáveis independentes de otimização. A fundamentação matemática do método encontra-se descrita em diversas referências



(BAUGHMAN e LIU, 1995; HAYKIN, 2001; DE SOUZA JR., 1993). Nesse mesmo sentido, Fonseca (1998) descreve a metodologia da técnica de treinamento por retropropagação, abordando os conceitos e, do ponto de vista de otimização, a função objetivo com a condição necessária para o mínimo, além de variantes do método.

Para o cálculo dos erros, Baughman e Liu (1995) apontam a utilização da Equação 2.3, para cada neurônio.

$$\epsilon_k = d_k - c_k \quad (2.3)$$

Onde  $\epsilon_k$  consiste no erro da saída (representado por um vetor),  $d_k$  representa a saída desejada (valor conhecido e pré-determinado) e  $c_k$  é o valor de saída calculado para o neurônio  $k$ , na camada de saída.

Em seguida, é calculado o erro quadrático através da Equação 2.4.

$$E = \sum_k \epsilon_k^2 = \sum_k (d_k - c_k)^2 \quad (2.4)$$

Conhecido o valor de  $E$ , pode-se então determinar a variação do peso para a conexão  $i$  do  $j^{\text{ésimo}}$  neurônio, conforme descrito na Equação 2.5.

$$\Delta w_{ij} = \eta_j \cdot a_i \cdot E \quad (2.5)$$

Onde  $\eta_j$  é a constante linear de proporcionalidade do neurônio  $j$  (normalmente  $0 < \eta_j \ll 1$ ) e  $a_i$  consiste na entrada  $i$  do neurônio  $j$ .

Vale ressaltar que para se utilizar o algoritmo de *backpropagation* é necessário que a rede neuronal artificial seja um *perceptron*, isto é, a conexão utilizada deve ser apenas entre camadas e *feedforward*.

Baughman e Liu (1995) descrevem também os seguintes algoritmos para ensino da RNA:

- Treinamento por reforço: trata-se de uma forma de aprendizagem simples, classificada como “seletivamente supervisionada”. Enquanto o algoritmo de *backpropagation* utiliza um vetor para classificação dos erros na saída, o

treinamento por reforço utiliza apenas um valor de erro, que representa toda a performance da rede neuronal artificial.

- Treinamento estocástico: utiliza dados estatísticos para ajustar os pesos entre os neurônios.
- Redes neuronais pré-determinadas: conforme o nome, são utilizadas redes neuronais artificiais cujas conexões e pesos são conhecidos. Dado ao conhecimento pré-determinado, este algoritmo apresenta como vantagem a rapidez em relação aos demais.
- Treinamento Hebbiano: o ajuste dos pesos é realizado através de correlação entre os dois neurônios associados.

O tempo gasto em treinamento varia em relação ao sistema em análise, sendo que para o algoritmo de *backpropagation* o critério de parada não é bem definido. Neste caso utiliza-se, normalmente, um número de ciclos pré-definidos.

Após o treinamento da rede, ocorre a fase de teste (verificação da performance da rede neuronal artificial estabelecida), a partir das seguintes etapas (BAUGHMAN e LIU, 1995):

- Etapa de recordação (*recall step*): são enviados dados de entrada, cujas saídas são conhecidas pela rede, para observação dos valores gerados.
- Etapa de generalização (*generalization step*): são enviados dados de entrada, cujas saídas são conhecidas pelo observador, porém desconhecidas pela rede, a fim de verificar os erros obtidos entre os valores preditos *versus* os valores observados. Esta última etapa tem como objetivo obter valores mínimos de erro.

A Figura 2.14 demonstra, como exemplo, uma curva de processo típico de aprendizado de uma rede neuronal artificial.

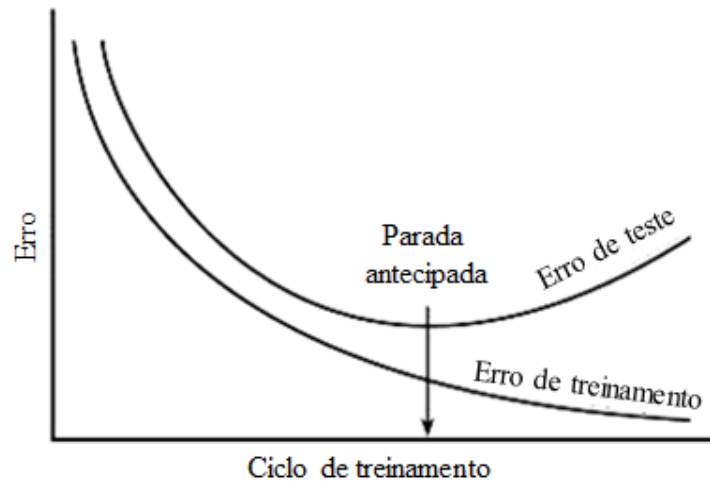


Figura 2.14 – Esquema de funcionamento do treinamento com os subconjuntos de dados para treinamento e para teste.

Fonte: Adaptado de Baughman e Liu (1995).

Pode-se verificar que, para ambas as etapas, é importante que se utilize uma grande quantidade de padrões no treinamento para que as respostas do sistema sejam eficazes. O critério de parada é adotado quando o erro de teste aumentar, apesar de erro treinamento diminuir.

Finalmente, é realizada a análise da RNA treinada com relação ao sistema de estudo, para verificar o seu desempenho.

## Capítulo 3 METODOLOGIA

Neste capítulo é descrita a planta piloto e a metodologia utilizada nos testes experimentais realizados na unidade experimental. Descreve-se também a metodologia da coleta dos dados para o treinamento das redes neurais artificiais, que constituem o sistema de estudo.

### 3.1 Descrição da planta

#### 3.1.1 Planta e Equipamentos

O equipamento utilizado como objeto de estudo é a Planta Didática da SMAR®, que consiste de um arranjo compacto de diversas malhas de controle, utilizando as instrumentações e ferramentas de configuração desenvolvidas para aplicação em controles industriais. Tal configuração permite ao usuário atuar na modificação de valores e registros internos, através de simulações reais (BOTTO e CASSIOLATO, 2012).

A planta em análise neste trabalho é a PD3 *Fieldbus*, adquirida através de projeto de auxílio a pesquisa da FAPERJ (E-26 110.861/2011). A Planta PD3 consiste de processo contínuo, composta basicamente de três tanques cilíndricos, cinco transmissores *Fieldbus*, duas bombas de partida direta, duas válvulas automáticas de controle, uma resistência de imersão, um painel de operação local e um CLP (modelo LC700, SMAR). A princípio este equipamento não tem como objetivo a produção de nenhum tipo de produto, sendo puramente experimental. O seu funcionamento, consiste basicamente na circulação de líquido através dos tanques, podendo existir estratégias diferentes de atuação sobre estes. A planta possui um tanque central, ou tanque reservatório, que tem a função de estocar o líquido que será enviado para os demais tanques, não existindo nenhum dispositivo de controle e automação. O transporte do líquido para os demais tanques (tanque de aquecimento e de mistura) é realizado por duas bombas, dispostas em paralelo, cujas vazões são manipuladas por válvulas automáticas, dispostas na entrada dos tanques. Ao longo das tubulações e nos tanques, existem ainda alguns transdutores que são responsáveis por monitorar a vazão, o nível e a temperatura, conforme manual da planta didática (SMAR).

A Figura 3.1 apresenta a planta PD3, em estudo.



Figura 3.1 - Planta Didática PD3 da SMAR.

O sistema da planta é dividido em dois setores (setor 31 e setor 32), sendo que a primeira constitui no tanque de aquecimento e os equipamentos auxiliares, enquanto que a segunda representa o tanque de mistura e seus equipamentos auxiliares. No descrito trabalho serão utilizadas nomenclaturas referentes a cada malha, conforme apresentado no diagrama P&ID da Figura 3.2. Para fins de estudo, o tanque reservatório foi denominado como setor 30.

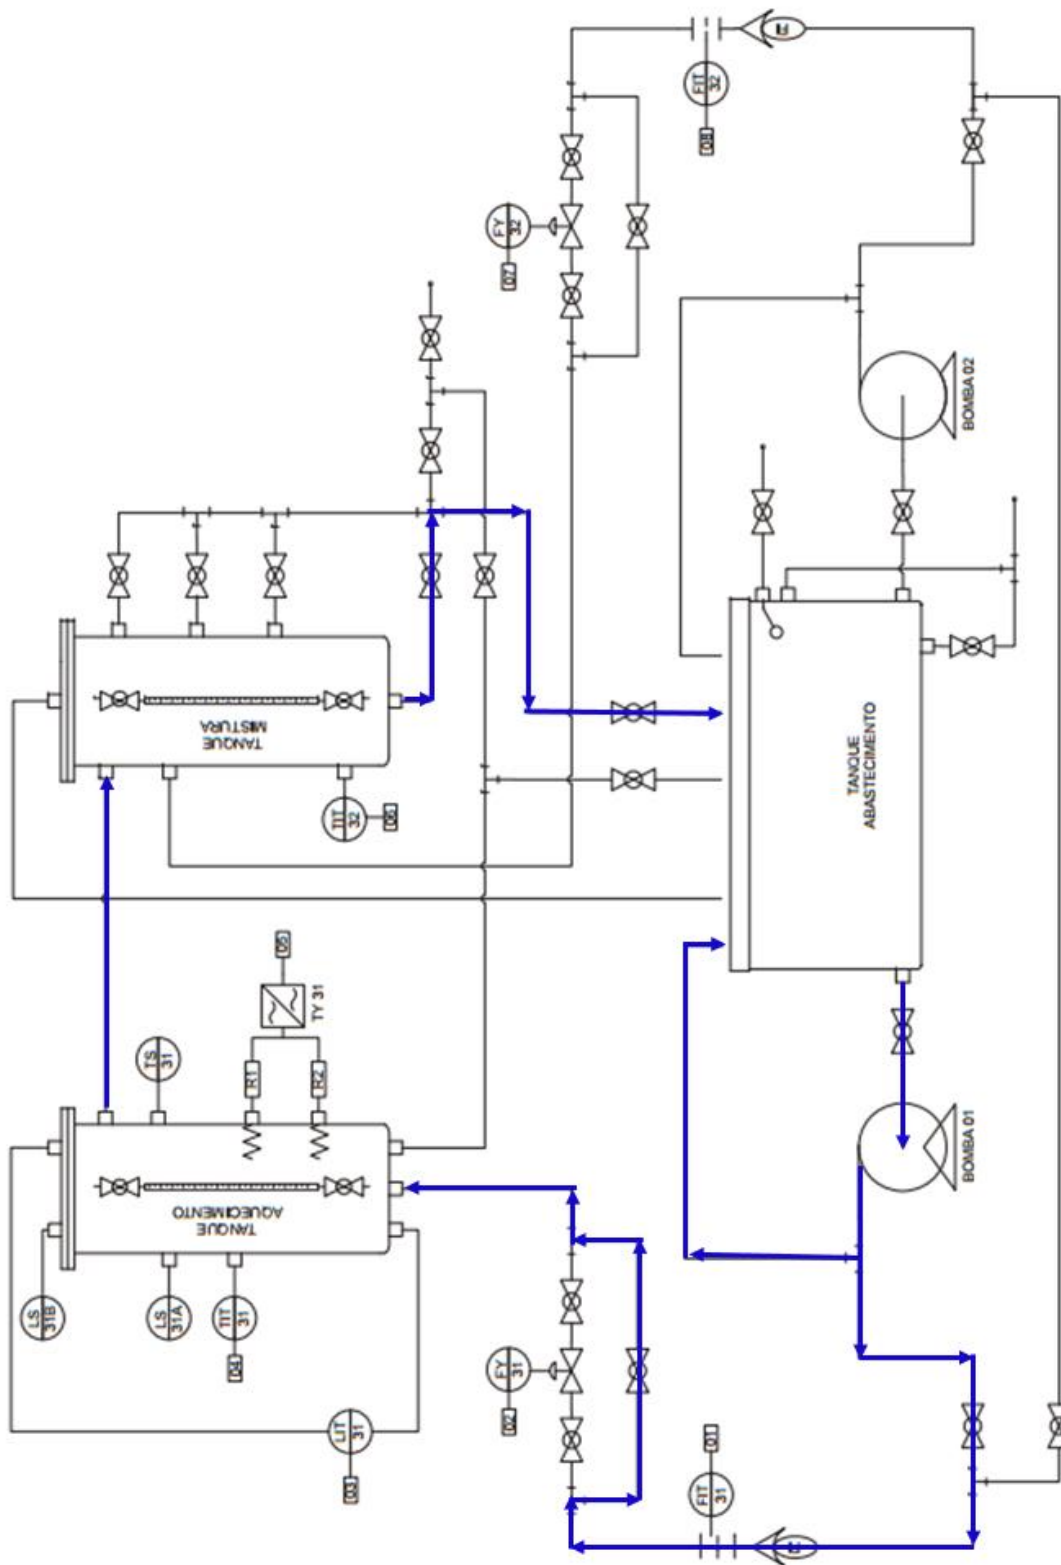


Figura 3.2 - Diagrama P&ID da planta PD3, com indicação do fluxo realizado pela água nos experimentos.

Fonte: Adaptado de manual da planta didática (SMAR).

A seguir são apresentados com maiores detalhes a instrumentação e *software* da planta:

- Plataforma de Controle e Automação de Processos, através do *System 302*.  
Dentre esta plataforma, a estação de trabalho mais comumente utilizada é o *Process View*, que oferece os seguintes pacotes:
  - ❖ *GraphworkX32*: responsável pela visualização do processo.
  - ❖ *AlarmWorkX32*: responsável pela aquisição e gerenciamento dos alarmes.
  - ❖ *TrendWorkX32*: responsável pela aquisição e gerenciamento de tendência (real e histórica).
- 1 tanque fechado de aquecimento, com 25 litros, presente na malha 31 (Tanque-31), onde a água do sistema é aquecida, através da resistência de imersão.
- 1 tanque de mistura, também fechado e com 25 litros, presente na malha 32 (Tanque-32), onde ocorre a mistura do líquido aquecido no Tanque-31 com a água fria proveniente do tanque reservatório.
- 1 tanque reservatório aberto, com 60 centímetros de diâmetro e aproximadamente 26 centímetros de altura máxima da água. Assim sendo, apresenta um volume total de 73,5 litros.
- 2 bombas hidráulicas que promovem a circulação de líquido pelas tubulações da planta. Consistem de moto-bombas centrífugas que possuem alto rendimento e possibilitam a elevação do fluido bombeado até 70 metros, sendo acionadas por motor de indução do tipo fechado e auto-ventilado (monofásico: 220 Vac – 60Hz).
- 2 válvulas automáticas de controle do tipo globo, pneumáticas, com diâmetro de 0,5 polegadas, que são responsáveis pelo controle do fluxo de líquido na planta.
- 2 rotâmetros, constituídos de tubos de vidro cônico, que permitem a indicação instantânea das vazões volumétricas de água que saem das respectivas bombas e seguem para os tanques de aquecimento e de mistura.
- 1 chave de nível, presente no Tanque-31, responsável por detectar quando o nível de água está baixo. Caso seja detectado, a chave de nível enviará um comando ao painel de controle, para inibir a potência transferida para a resistência. Este equipamento atua através do princípio de condutividade e

impede a queima das resistências contidas no tanque, uma vez que estas atuam em imersão.

- 1 conversor estático, responsável por alimentar as resistências elétricas presentes no Tanque-31. Apresenta como benefícios: precisão, limitação por fator de demanda, aumento da vida útil das resistências e redução do consumo de energia.
- 2 resistências de imersão, presentes no Tanque-31, responsáveis pelo aquecimento do líquido do tanque. Ambas possuem potência de 2100 W x 220V.
- 1 termostato, responsável por enviar um sinal que iniba o conversor estático quando a temperatura do Tanque-31 atingir o limite máximo informado.
- 1 sensor de temperatura PT-100, responsável pela medição da temperatura no Tanque-31, fundamentada na variação da resistência elétrica de um condutor metálico em função da temperatura.
- 1 sensor de temperatura do tipo termopar J, responsável pela medição da temperatura no Tanque-32.
- 3 transmissores de pressão diferencial *Foundation Fieldbus*, que realizam a medição da pressão por célula capacitativa, utilizando um microprocessador em seus circuitos eletrônicos.

As *Tag's* utilizadas são:

- ❖ FIT-31: transmissor indicador da vazão de alimentação no tanque de aquecimento;
  - ❖ FIT-32: transmissor indicador da vazão de alimentação no tanque de mistura;
  - ❖ LIT-31: transmissor indicador do nível de água no tanque de aquecimento.
- 2 transmissores de temperatura *Foundation Fieldbus*, capazes de aceitar o uso de sensores que gerem resistência ou milivoltagem, além das medições de temperatura por termoresistências ou termopares.

As *Tag's* utilizadas são:

- ❖ TIT-31: transmissor indicador da temperatura no tanque de aquecimento;
- ❖ TIT-32: transmissor indicador da temperatura no tanque de mistura.



- 2 posicionadores de válvula *Foundation Fieldbus*, responsáveis pela ativação nas válvulas de controle pneumáticas, através da produção de pressão de saída requerida para o posicionamento, conforme o sinal *Fieldbus* de entrada.

As *Tag*'s utilizadas são:

- ❖ FY-31: conversor de sinal para a válvula de água quente;
- ❖ FY-32: conversor de sinal para a válvula de água fria.
- 1 conversor *Foundation Fieldbus*, que converte um sinal *Fieldbus* em um sinal de 4 a 20 mA.

A *Tag* utilizada é:

- ❖ TY-31: corrente para modular a potência de saída do conversor estático.
- 2 controladores de temperatura, indicados pelas seguintes *Tag*'s:
  - ❖ TIC-31: controlador da temperatura do tanque de aquecimento;
  - ❖ TIC-32: controlador da temperatura do tanque de mistura.
- Tubulação, conexões, parafusos e porcas em estruturas de aço inox AISI-304. A planta apresenta também válvulas manuais esferas em aço inox CF8.

### 3.1.2 Sistema Supervisório

Segundo Gaushell (1987) os sistemas supervisórios foram implementados a fim de capturar e armazenar as informações do processo em um banco de dados. A partir deste sistema é apresentada a interface homem/máquina através de uma tela configurada ao processo em análise, facilitando o monitoramento e o controle das variáveis, com rápida ação pelo usuário.

A interface dos dados experimentais com o computador ocorre através da interligação de ambos a partir de um controlador lógico programável (CLP).

Em relação à planta PD3, deve-se ressaltar que o sistema supervisório é constituído pelo padrão *OPC Foundation* e pelo sistema *SCADA*, isto é, apresenta uma interface de aplicações mais eficiente (*OPC, OLE for Process Control*) com o controle e aquisição dos dados em tempo real (*SCADA, Supervisory Control And Data Acquisition*).

A Figura 3.3 apresenta o sinótico da Planta PD3.




Figura 3.3 – Sinótico da planta PD3.

Fonte: manual da planta didática (SMAR).

### 3.1.3 Objeto de Estudo

No presente trabalho estudou-se o sistema de aquecimento do Tanque-31, da planta PD3, conforme especificado anteriormente na Figura 3.2.

A partir deste esquema verifica-se que a temperatura do Tanque-31 é afetada por diversos fatores: nível de água no tanque; vazão volumétrica de água na linha; efeito da variável manipulada; valor determinado como *setpoint*; temperatura de entrada (temperatura do tanque reservatório) e efeito da resistência de imersão. Outro fator que também afeta está relacionado ao calor dissipado pela bomba, durante o seu funcionamento nas corridas experimentais.

Assim sendo, é notável a complexidade para modelar o sistema em estudo (tendo como objetivo a sintonia dos controladores), devido às características não lineares do controle do processo. Braga, Carvalho e Ludermir (2011) apontam que os métodos clássicos utilizados na modelagem de sistemas não lineares apresentam eficiência, porém podem não retratá-los de forma fidedigna. Estes métodos também tornam-se demasiadamente complexos ao se considerar um grande número de variáveis de entrada. Em contrapartida, as redes neurais artificiais são consideradas ferramentas bastante apropriadas para tal uso, tendo em vista a sua grande capacidade para descrever processos complexos.

Desta forma, neste estudo utilizou-se para modelagem matemática a técnica de RNA.

## 3.2 Coleta de Dados

A fim de obter dados representativos do objeto em estudo, optou-se pela realização de testes através da modificação da vazão de entrada no tanque de aquecimento (FIT-31) e da temperatura desejada na malha de controle 31. Neste caso, a coleta de dados foi realizada nas condições descritas nos próximos tópicos.

O fluido utilizado para análise foi a água, considerando as temperaturas desejadas (T-31 D) iguais a 40, 50 e 60°C. Cada temperatura foi testada para as seguintes vazões da malha 31: 400, 600 e 800 L/h. Estas vazões foram ajustadas através da posição de abertura da válvula de alimentação do tanque de aquecimento. Sendo assim, foram realizados 9 experimentos, conforme representados na Tabela 3.1.

Tabela 3.1 - Testes experimentais para representação do sistema e treinamento da RNA.

<b>Nº Experimento</b>	<b>FIT-31 (L/h)</b>	<b>T-31 D (°C)</b>
<b>1</b>	400	40
<b>2</b>	600	40
<b>3</b>	800	40
<b>4</b>	400	50
<b>5</b>	600	50
<b>6</b>	800	50
<b>7</b>	400	60
<b>8</b>	600	60
<b>9</b>	800	60

A fim de descrever o sistema, a malha de controle não foi utilizada, isto é, utilizou-se a linha de *by-pass* para a alimentação da água no Tanque-31, enquanto que a linha da válvula de controle estava fechada. Na Figura 3.2 (apresentada previamente) pode-se verificar uma ilustração na qual as linhas destacadas representam o caminho realizado pela água durante os experimentos. É importante ressaltar que a variação da corrente elétrica para alimentação da resistência alocada no Tanque-31 também foi realizada manualmente.

Inicialmente realizou-se o aquecimento da água no Tanque-31 sem que houvesse retorno da água quente para o sistema. Na sequência os demais experimentos foram realizados fazendo com que a água aquecida no Tanque-31 retornasse ao Tanque Reservatório.

Realizou-se a coleta de dados de todas as variáveis medidas pela planta PD3, referentes à malha 31. Sendo assim, as variáveis consideradas foram:

- T-31 D (°C): temperatura desejada para a água no Tanque-31.
- T-31 MV (%): variável manipulada, diretamente ligada à resistência do Tanque-31.
- TY-31 (mA): corrente para modular a potência de saída do conversor estático. Apresenta valores entre 4 a 20 mA, equivalentes a 0 e 100%, respectivamente.
- TIT-31 (°C): temperatura real do Tanque-31.
- FY-31 (%): conversor de sinal para a válvula de alimentação do Tanque-31.
- LIT-31 (%): indicador do percentual de nível de água no Tanque-31.
- FIT-31 (L/h): vazão volumétrica de água na malha 31.
- T-30: temperatura no tanque reservatório. Esta medida não é realizada pela planta PD3, sendo assim, a medição ocorreu pontualmente, a cada 10 minutos, a partir de um termopar K *offline*. Ao final, como as variações foram pequenas, interpolou-se os valores para a obtenção das temperaturas durante todos os tempos da coleta de dados na planta.

Cada experimento teve duração de 2 horas, pois verificou-se que este tempo era eficaz para que o sistema pudesse atingir o novo estado estacionário nas temperaturas estabelecidas.

O tempo de coleta dos dados experimentais foi realizado a cada 10 segundos, a fim de obter grande quantidade de dados, para serem utilizados no treinamento das redes neurais artificiais. Outro fator a ser ressaltado é que a coleta dos dados foi obtida através do sistema supervisor da planta, no qual gerou arquivos em .CSV. A base de dados foi tratada a partir de uma máscara desenvolvida previamente para a planta (MELAZZI, SILVA e RAMIREZ, 2015), obtendo os dados separados para cada intervalo do tempo de coleta (*vide* Figura 3.4).

Data: 22/05/2015

Descrição dos Equipamentos:	TIC-31	T-31 SP	T-31 MV	TIC-32	TY-31	LI-31	FY-31	FY-32	FI-31	FI-32	LI-31
	Good	Good	Good	Good	Good	Good	Good	Good	Good	Good	Good

Tempo (hh:mm:ss)	Tempo (min)	TIC-31 (°C)	T-31 SP (°C)	T-31 MV (%)	TIC-32 (°C)	TY-31 (mA)	LI-31 (%)	FY-31 (%)	FY-32 (%)	FI-31 (L/h)	FI-32 (L/h)	LI-31
15:08:27	0,00	24,04	10,00	0,00	24,16	4,00	111,40	0,00	0,00	406,67	0,00	405,52
15:08:40	0,21	24,05	10,00	0,00	24,16	4,00	111,44	0,00	0,00	405,67	0,00	405,38
15:08:52	0,41	24,05	60,00	100,00	24,15	20,00	111,43	0,00	0,00	405,55	0,00	406,38
15:09:04	0,62	24,05	60,00	100,00	24,15	20,00	111,42	0,00	0,00	404,45	0,00	404,65
15:09:17	0,82	24,08	60,00	100,00	24,20	20,00	111,39	0,00	0,00	408,38	0,00	405,14
15:09:30	1,05	24,82	60,00	100,00	24,34	20,00	111,39	0,00	0,00	406,40	0,00	405,30
15:09:42	1,25	25,24	60,00	100,00	24,53	20,00	111,36	0,00	0,00	404,20	0,00	405,71
15:09:55	1,46	25,66	60,00	100,00	25,22	20,00	111,31	0,00	0,00	402,58	0,00	405,09
15:10:07	1,66	26,06	60,00	100,00	25,33	20,00	111,31	0,00	0,00	403,33	0,00	403,93
15:10:19	1,87	26,81	60,00	100,00	25,48	20,00	111,27	0,00	0,00	404,45	0,00	403,57
15:10:32	2,08	27,92	60,00	100,00	25,65	20,00	111,27	0,00	0,00	404,20	0,00	405,04
15:10:44	2,28	27,85	60,00	100,00	25,89	20,00	111,25	0,00	0,00	404,44	0,00	403,24
15:10:57	2,51	28,47	60,00	100,00	26,50	20,00	111,22	0,00	0,00	403,21	0,00	404,57
15:11:10	2,71	28,92	60,00	100,00	26,65	20,00	111,20	0,00	0,00	404,19	0,00	404,69
15:11:22	2,92	28,91	60,00	100,00	26,78	20,00	111,20	0,00	0,00	404,56	0,00	404,31
15:11:35	3,12	28,87	60,00	100,00	27,02	20,00	111,17	0,00	0,00	403,57	0,00	403,95
15:11:47	3,33	28,86	60,00	100,00	27,25	20,00	111,16	0,00	0,00	405,18	0,00	404,63
15:11:59	3,53	28,99	60,00	100,00	28,00	20,00	111,13	0,00	0,00	406,17	0,00	404,74
15:12:12	3,74	29,36	60,00	100,00	28,08	20,00	111,09	0,00	0,00	406,42	0,00	404,22
15:12:24	3,95	30,11	60,00	100,00	28,22	20,00	111,09	0,00	0,00	405,82	0,00	404,24
15:12:37	4,17	29,74	60,00	100,00	28,42	20,00	111,09	0,00	0,00	404,95	0,00	403,64

Figura 3.4 - Dados experimentais trabalhados pela máscara desenvolvida para o sistema.

Ao final, foram obtidos 5.193 dados individuais para as variáveis TIC-31, T-31 SP, T-31 MV, TY-31, LI-31 e FI-31, em função dos tempos de coleta.

Uma vez que os dados de T-30 foram medidos *offline* a cada 10 minutos, obteve-se 117 dados experimentais. Para obter maior quantidade de dados, foi necessário realizar a interpolação para este conjunto de dados em intervalos de 10 segundos. Assim, foram gerados 5.193, distribuídas nos mesmos intervalos de tempo das demais variáveis empregadas para o treinamento da RNA.

### 3.3 Treinamento da RNA

Como o objeto de estudo estava relacionado à temperatura do Tanque-31, estudou-se, através de RNA, a correlação das variáveis de entrada com a temperatura final (variável de saída). Este estudo será abordado no próximo capítulo, no qual será discutida também a importância de cada variável no modelo de rede final.

O treinamento das redes neurais artificiais foi efetuado no pacote *STATISTICA AUTOMATED NEURAL NETWORK* (SANN) do *software* Statistica® 12.0 da (STATSOFT, INC., 2013).

A Figura 3.5 apresenta os dados experimentais que foram considerados, inicialmente, para o treinamento das redes neurais artificiais.

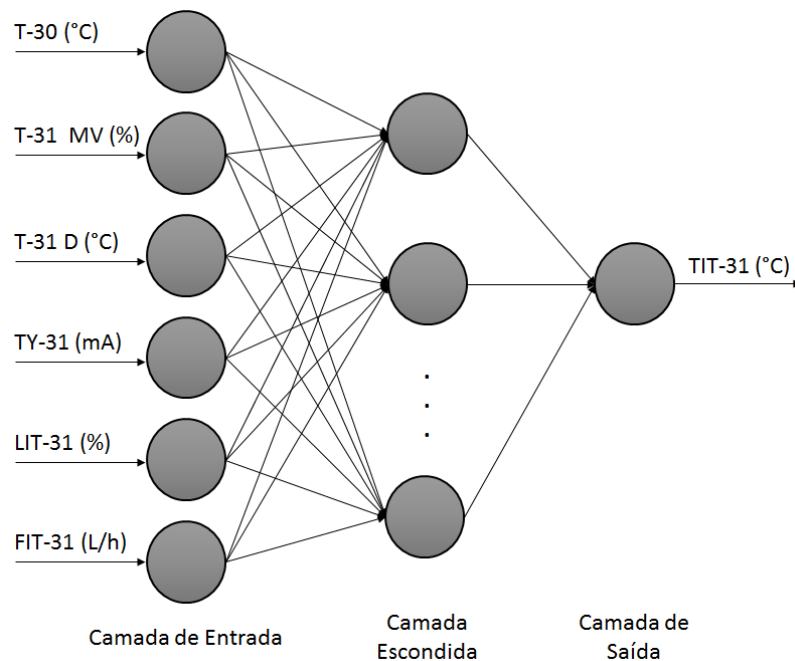


Figura 3.5 – Estrutura da RNA estudada.

Os dados de entrada e de saída foram analisados por regressão, sendo este método comumente utilizado para a previsão de uma ou mais variáveis contínuas com um conjunto de entradas (STATSOFT, 2015). Foram realizados diversos treinamentos a fim de obter a melhor rede, sendo que em cada, foram treinadas 500 redes, considerando as arquiteturas disponíveis pelo programa (*Perceptron de Múltiplas Camadas*, ou MLP e *Função de Bases Radiais*, ou RBF) e todas as funções de ativação para a camada escondida e a camada de saída (Identidade, Logística, Tangente Hiperbólica, Exponencial e Seno). Destas redes treinadas foram retidas as cinco melhores para análise.

Em relação ao número de neurônios na camada escondida, utilizou-se a faixa de 3 a 25 neurônios para a MLP (aumentando o padrão pré-estabelecido pelo programa) e 21 a 30 neurônios para a RBF (valor pré-estabelecido pelo programa). Segundo o tutorial do STATISTICA 12.0, o aumento do número de neurônios presentes na camada escondida aumenta o poder da modelagem da rede neuronal artificial, sendo adequado para casos onde existe grande número de dados. Porém, não se deve aumentar em demasia este número, pois acarreta o aumento do número de parâmetros (pesos e “*bias*”), levando à redução do número de graus de liberdade do sistema. Tal procedimento torna o treinamento mais lento, propiciando a ocorrência do fenômeno denominado *overfitting* (sobre-treinamento). Segundo De Souza Jr. (1993) o sobre-treinamento ocorre quando a RNA perde a capacidade de generalização de novos dados, apesar de tornarem-se hábeis para representar o sistema.

Para evitar o *overfitting*, o SANN (*Statistica Automated Neural Networks*) utiliza uma amostra de teste, que auxilia no treinamento. Desta forma, os conjuntos de dados podem ser historicamente divididos em três subconjuntos de dados: treinamento, teste e validação; sendo a proporção de 14:3:3 (70%:15%:15%). Essa proporção para delinear os subconjuntos de dados constitui-se a condição padrão apresentada pela versão 12 do programa Statistica, empregada neste trabalho. De Souza Jr. (2003) e Baughman e Liu (1995), propuseram também a alternativa de divisão dos subconjuntos de treinamento e teste na proporção de 3:1. Analogamente, para a seleção dos subconjuntos de dados de treinamento/teste/validação, poder-se-ia utilizar as proporções 50%:25%:25% ou 2:1:1.

Inicialmente foram realizados alguns testes empregando a seleção dos subconjuntos de dados de treinamento/teste/validação, todavia não foram obtidos resultados satisfatórios. Assim, considerou-se a quantidade de dados históricos disponível relativamente pequena para o treinamento e não foi selecionado o subconjunto de dados para validação. A proporção do subconjunto de dados para treinamento/teste usada foi 4:1.

O critério de parada do treinamento está relacionado ao cálculo dos erros de treinamento e de teste (*vide* Capítulo 2). Estes valores determinam o desempenho da rede e são calculados pelo método dos mínimos quadrados (*vide* Capítulo 2, seção 2.3.3), ao final de cada iteração. Assim, enquanto os erros diminuem, o treinamento prossegue. Não obstante, caso os erros não se alterem, diz-se que a solução foi atingida, e assim o SANN finaliza o treinamento. Outro critério de parada é quando o erro de teste permanece constante, ou aumenta, mesmo que o erro de treinamento diminua, pois esta condição é indicativa de sobre-treinamento (*overfitting*). O fenômeno de *overfitting* torna a RNA hábil para representar os dados de treinamento, todavia perde a capacidade de generalização para novos dados (DE SOUZA JR., 1993).

Para avaliação do desempenho da RNA, o SANN contém em seu pacote alguns critérios estatísticos, dentre os quais foram empregados: valores dos pesos e “*bias*” de cada conexão, dados estatísticos, análise de sensibilidade, gráficos dos resíduos e dados preditos pela rede x dados experimentais.

É importante destacar também a possibilidade de avaliar a contribuição de cada variável de entrada da rede a partir da análise de sensibilidade. Baughman e Liu (1995) apontam que esta análise classifica cada variável a partir de um número de *RATIO*. Quanto maior for o valor, maior a contribuição desta variável de entrada para o treinamento da rede. Caso este valor seja menor ou igual a 1, indica a possibilidade da rede apresentar melhor performance sem a inserção dessa variável na camada de entrada.

O *RATIO* é definido como a razão de sensibilidades, sendo calculado pela razão do erro global da rede, calculado para o valor médio dos dados antecessores e o erro global calculado para o valor real do dado (BOARETO MENDES, 2005).

Assim, as redes neuronais artificiais foram treinadas inicialmente utilizando todo o conjunto de variáveis de entrada disponíveis. Na sequência, procedeu-se o teste de sensibilidade (*RATIO*) para avaliar quais das variáveis apresentaram baixa contribuição no treinamento, removendo-as uma a uma até convergir para a melhor condição de treinamento.

No próximo capítulo os resultados serão apresentados e discutidos.



## Capítulo 4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos no emprego de metodologia destinada à obtenção da RNA que melhor representa o processo. De início apresenta-se a rede neuronal artificial treinada, considerando todas as variáveis de entrada. Na sequência são avaliadas novas redes, cujos treinamentos foram realizados retirando-se da camada de entrada os dados com baixas contribuições. Ao final são discutidos os testes estatísticos referentes à RNA de melhor performance, visando a avaliação do desempenho da mesma.

### 4.1 Obtenção dos Dados Experimentais

Conforme descrito no capítulo anterior, foi realizado um primeiro experimento considerando o aquecimento da água no Tanque-31 sem recirculação, ou seja, sem o retorno do fluxo aquecido para o Tanque reservatório. Não obstante, verificou-se não ser possível realizar este experimento, uma vez que a planta PD3 não teve capacidade para aquecer o fluido até a temperatura definida como a desejada (40°C) com alimentação contínua de água fria.

A Figura 4.1 apresenta o perfil dinâmico de troca térmica do experimento com alimentação contínua do fluido frio, sem recirculação.




Figura 4.1 - Experimento realizado sem recirculação de água quente no sistema.

Assim sendo, os demais experimentos foram efetuados com recirculação de água quente na planta (sistema fechado).

A Figura 4.2 apresenta os valores de temperatura da água no Tanque-31, obtidos experimentalmente, dispostos na sequência de dados de cada experimento.




Figura 4.2 - Sequência de dados experimentais da temperatura da água no Tanque-31.

Os demais valores experimentais são demonstrados através da sequência de dados nas Figuras 4.3 (T-30), 4.4 (T-31 MV e TY-31), 4.5 (FIT-31) e 4.6 (LIT-31).




Figura 4.3 - Sequência de dados experimentais da temperatura da água no Tanque-30.

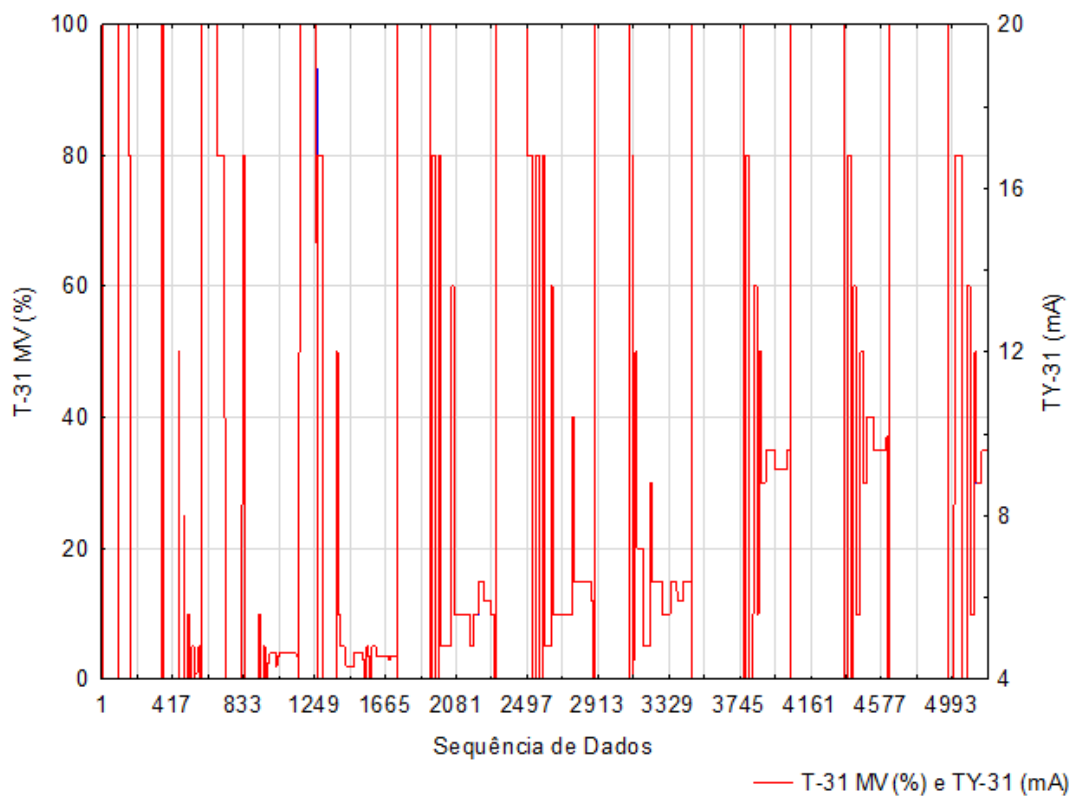


Figura 4.4 - Sequência de dados experimentais das variáveis T-31 MV e TY-31.




Figura 4.5 - Sequência de dados experimentais da vazão no Tanque-31.




Figura 4.6 - Sequência de dados experimentais do nível da água no Tanque-31.

Na sequência estes valores foram utilizados para o treinamento das redes neuronais artificiais, conforme será descrita na próxima seção.

## 4.2 Treinamento da RNA com Todas as Variáveis de Entrada

Conforme descrito previamente, o treinamento da RNA ocorreu no programa STATISTICA (versão 12).

Inicialmente foi realizado o treinamento utilizando os dados experimentais de todas as variáveis selecionadas para a malha 31.

Na Figura 4.7 estão esquematizadas as variáveis de entrada e de saída.




Figura 4.7 – Esquema de entrada e saída utilizado no treinamento da RNA.

A rede estruturada apresenta 6 neurônios na camada da entrada e 1 neurônio na camada de saída, correspondentes às variáveis do sistema. Através do treinamento foi determinado o número de neurônios na camada escondida e estimados os pesos e “*bias*” de cada conexão.

Em função da quantidade de dados disponíveis para o treinamento das redes neuronais artificiais não foi adequado utilizar o subconjunto de dados de validação, uma vez que interferiu negativamente no treinamento da RNA (altos erros obtidos e baixas performances).

Assim, tendo em vista a quantidade de dados experimentais e a falta de dados extras para a execução da RNA, foram realizados diversos treinamentos sem utilizar a amostra de validação. Nas próximas seções serão apresentadas as redes e serão utilizadas técnicas estatísticas no sentido de confirmar a capacidade preditiva da rede neuronal artificial que constitui o sistema.

### 4.2.1 Análises de Desempenho

Ao final do treinamento foram retidas as cinco melhores redes, apresentadas na Tabela 4.1.

Tabela 4.1 - Cinco melhores redes treinadas com seis variáveis de entrada e uma variável de saída.

Nº	RNA	Performance		Erro		Função de Ativação: Camada Escondida/ Camada de Saída
		Treinamento	Teste	Treinamento	Teste	
1	MLP 6-21-1	0,999186	0,999129	0,068867	0,077443	Logística/ Tangente Hiperbólica
2	MLP 6-24-1	0,999209	0,999214	0,066907	0,069952	Logística/ Tangente Hiperbólica
3	MLP 6-23-1	0,999233	0,999259	0,064914	0,065847	Exponencial/ Logística
4	MLP 6-21-1	0,999223	0,999247	0,065703	0,067009	Tangente Hiperbólica/ Identidade
5	MLP 6-23-1	0,999194	0,999152	0,068192	0,075398	Logística/ Exponencial

Um ponto de destaque é que das 500 redes treinadas, apenas as arquiteturas MLP se destacaram entre as melhores selecionadas, demonstrando que esta arquitetura descreve melhor o sistema. Haykin (2001) comprova este ponto ao citar que a MLP é comumente utilizada para problemas de regressão, enquanto que a RBF é utilizada para problemas de classificação de padrões.

No treinamento descrito acima verificou-se também que a terceira rede (MLP 6-23-1) apresentou melhor resultado que as demais, uma vez que esta possui o menor erro de teste. Este fator é utilizado para identificar o melhor desempenho, pois é obtido a partir da avaliação dos dados não utilizados para o treinamento das redes, ou seja, não estão envolvidos no ajuste dos pesos e “*bias*”.

Outro fator que deve ser considerado na escolha da melhor rede são as performances de treinamento e de teste. O tutorial do STATISTICA 12.0 descreve a performance como sendo o coeficiente de correlação entre os valores preditos pela rede e os valores observados (reais). Estes coeficientes apresentam valores entre -1 e +1, sendo que, normalmente, os valores próximos a +1 indicam o melhor ajuste. Porém, uma vez que os dados iniciais apresentam, no geral, uma quantidade de ruídos, os coeficientes de performance de treinamento podem estar elevados, mas apresentando baixas performances nas amostras de teste. Sendo assim, para

realizar a escolha da melhor rede deve-se avaliar tanto as performances de treinamento e de teste, quanto os erros de teste.

Para este caso, verificou-se que a rede selecionada apresentou os melhores valores em relação a estes critérios estatísticos discutidos.

Nesta rede MLP 6-23-1, foi utilizada a arquitetura *Perceptron* de Múltiplas Camadas (MLP), sendo constituída por 6 neurônios na camada de entrada, 23 neurônios na camada escondida e 1 neurônio na camada de saída.

Verifica-se também que a função de ativação utilizada na camada escondida foi a exponencial, enquanto que a função na camada de saída foi a logística.

Sendo assim, como a RNA MLP 6-23-1 apresentou o melhor desempenho dentre as demais, serão realizadas análises complementares para validar a sua adequação na representação do sistema em estudo.

#### 4.2.2 Dados Preditos pela RNA versus Dados Observados

Inicialmente avaliou-se a distribuição dos resíduos de rede, ou seja, a diferença entre os valores preditos *versus* os valores observados. Na Figura 4.8 verificou-se que a distribuição dos resíduos se aproximam de uma distribuição normal, o que significa que a rede representou adequação estatística ao ruído.




Figura 4.8 - Histograma de distribuição dos resíduos.

Montgomery e Runger (2013) complementam que a distribuição normal constitui em um modelo razoável de medidas da resistência à compressão, apresentando discernimento acerca da população.

Na sequência avaliou-se a dispersão dos valores preditos pela RNA em relação aos valores observados (reais). A Figura 4.9 apresenta o gráfico gerado para esta avaliação.

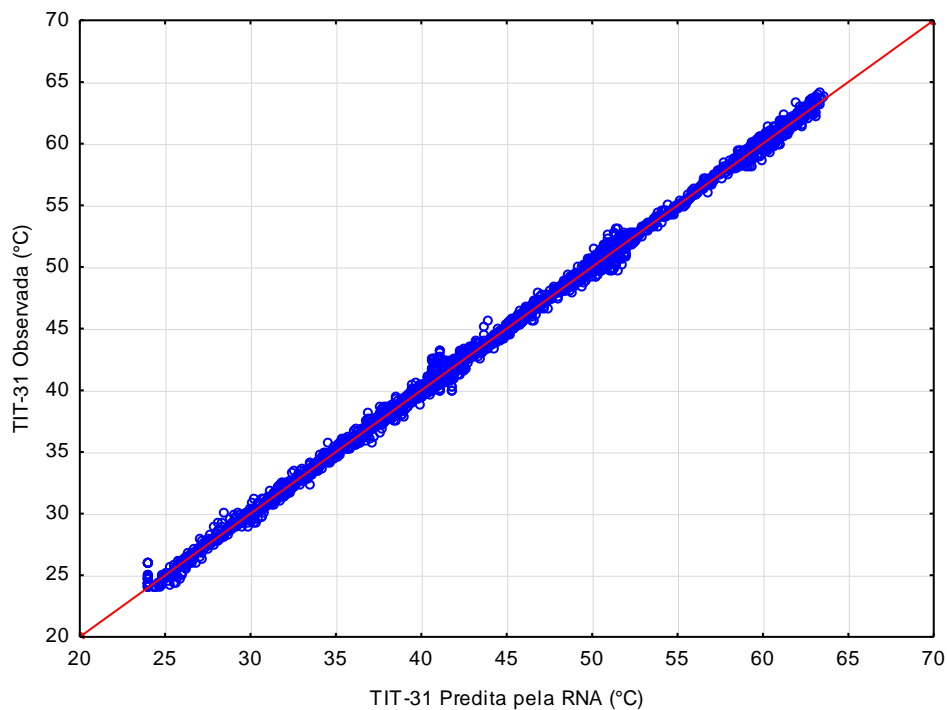


Figura 4.9 - Dados preditos pela RNA vs. dados observados.

Uma vez que os pontos estão distribuídos próximos da linha de ajuste, observou-se que os dados experimentais apresentaram alta correlação com os dados preditos (MONTGOMERY e RUNGER, 2013). Sendo assim, pôde-se afirmar que a rede neuronal artificial representou com significância estatística os dados experimentais.

#### 4.2.3 Comparação entre os Dados Experimentais e os Dados Preditos

A Figura 4.10 apresenta o gráfico da comparação dos dados preditos pela rede com os dados observados, durante a etapa de treinamento.



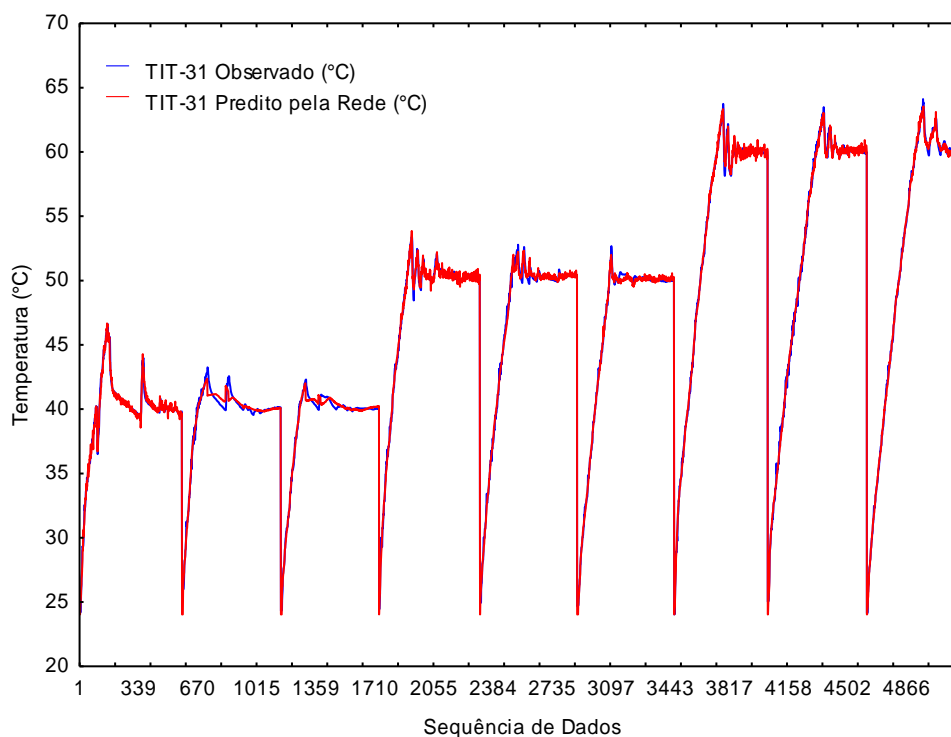


Figura 4.10 – Temperatura do Tanque-31 *versus* sequência de dados: comparação dos dados preditos pela RNA com os dados experimentais.

Conforme discutido na análise anterior, a rede selecionada apresentou alta capacidade de representação do sistema. Tal constatação também foi demonstrada pela Figura 4.14, onde os dados preditos pela rede apresentaram valores bem próximos aos valores observados, com pequenos desvios.

#### 4.2.4 Análise dos Dados Estatísticos

A estatística da regressão do treinamento da rede MLP 6-23-1 é apresentada na Tabela 4.2.

Tabela 4.2 - Estatística da regressão para a rede neuronal artificial para a variável de saída (MLP 6-23-1).

	<b>TIC-31 (°C)</b>
Média dos dados ( $\mu$ )	46,2913
Desvio padrão dos dados ( $\sigma$ )	9,24774

Segundo Montgomery e Runger (2013), o desvio padrão dos dados deve ser pelo menos uma ordem de grandeza menor que a sua média. Adotando esta afirmativa e analisando a tabela anterior, verifica-se que os dados utilizados no treinamento da rede MLP 6-23-1 apresentam desvios um pouco acima do proposto. Entretanto, constatou-se, através das outras análises estatísticas, que a rede neuronal artificial atende às características do processo.

#### 4.2.5 Análise de Sensibilidade

Conforme descrito previamente é possível identificar a importância relativa das variáveis utilizadas na camada de entrada da RNA, através da análise de sensibilidade (BAUGHMAN e LIU, 1995).

O SANN realiza a análise testando como as taxas de erro se comportam quando as variáveis de entrada são submetidas a alterações. Ao final cada variável é classificada com um valor de *RATIO*. O valor de *RATIO* igual ou menor que 1, indica que a variável não contribuiu significativamente para o treinamento da rede. Em contraste, quanto maior for o valor do *RATIO*, maior será a contribuição desta variável (BAUGHMAN e LIU, 1995).

Sendo assim, a Tabela 4.3 apresenta os valores obtidos para a análise de sensibilidade das cinco melhores redes retidas.

Tabela 4.3 - Análise de sensibilidade do treinamento realizado com seis variáveis de entrada.

Nº	RNA	T-30 (°C)	LIT-31 (%)	FIT-31 (L/h)	T-31 MV (%)	T-31 D (°C)	TY-31 (mA)
1	MLP 6-21-1	404,337	111,7951	131,4336	91,5114	22,958	50,897
2	MLP 6-24-1	658,163	123,8733	99,8096	77,7228	69,7755	75,6335
3	MLP 6-23-1	225,007	457,3643	171,5892	29,8795	78,5247	32,556
4	MLP 6-21-1	270,339	265,7626	163,2288	246,166	81,9651	98,1524
5	MLP 6-23-1	6560,092	165,7333	102,8749	36,2281	47,9758	40,3463
-	Média	1623,588	224,9057	133,7872	96,3016	60,2398	59,517

Verificou-se que apesar dos dados apresentarem *RATIO* acima de 1, algumas variáveis apresentaram valores bem menores em relação a outras.

Ao se analisar a média, percebeu-se que a corrente para modular a potência de saída do conversor estático (TY-31) apresentou menor influência dentre as demais variáveis, enquanto

que ao se analisar a melhor rede (terceira), verificou-se que a variável manipulada (T-31 MV) obteve menor resultado.

Logo, foram realizados novos treinamentos, retirando os dados com menores *RATIO* (TY-31 e T-31 MV) a fim de verificar se as novas redes apresentariam menores erros de teste, isto é, apresentam melhor modelagem em relação ao sistema.

Em cada treinamento foram adotados ajustes mais específicos, para que não fossem gastos tempos com treinamentos de redes de baixas performances. Logo, foram treinadas 200 redes, considerando apenas as arquiteturas MLP, com 11 a 25 neurônios na camada escondida, com função de ativação exponencial para a camada escondida e função de ativação logística para a camada saída.

Na próxima serão discutidos os resultados dos novos treinamentos, através da comparação dos modelos finais.

### 4.3 Comparação de desempenho das melhores RNA's

Nesta etapa foram realizados dois novos treinamentos a fim de comparar o desempenho das melhores redes de cada treinamento.

Sendo assim, os treinamentos foram classificados conforme abaixo:

- Treinamento 1: treinamento inicial, incluindo todos os dados experimentais das 6 variáveis de entrada definidas para o processo em estudo. Este modelo foi discutido na Seção 4.2.
- Treinamento 2: treinamento realizado sem considerar a variável manipulada (T-31 MV) na camada de entrada (*vide* Figura 4.11).

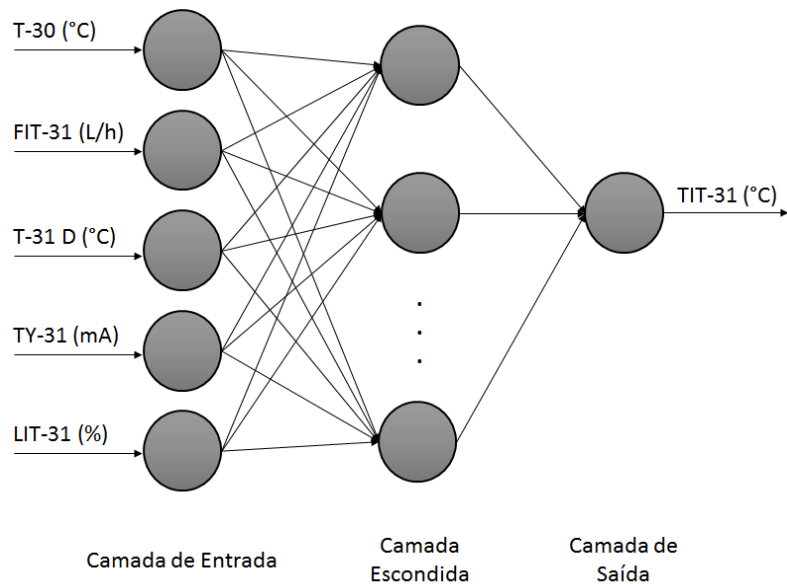


Figura 4.11 - Estrutura utilizada no 2º Treinamento da RNA.

- Treinamento 3: treinamento realizado sem considerar a corrente para modular a potência de saída do conversor estático (TY-31) na camada de entrada (*vide* Figura 4.12).

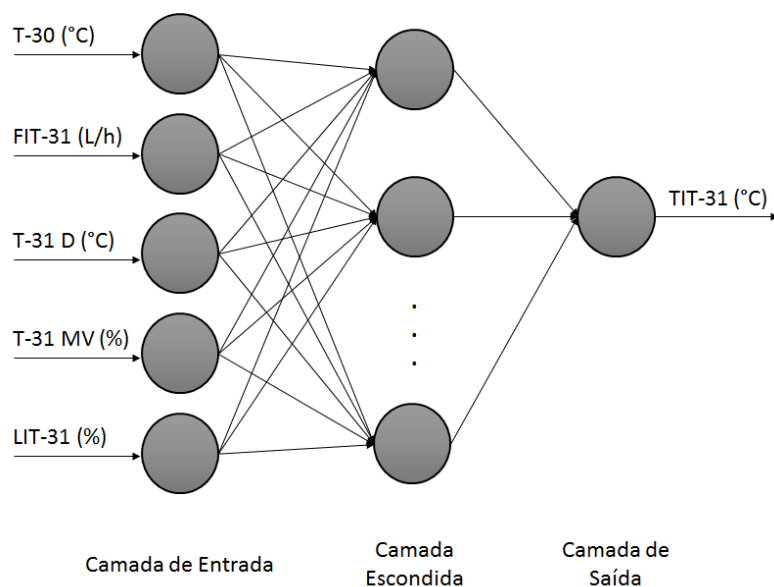


Figura 4.12- Estrutura utilizada no 3º Treinamento da RNA.

A fim de facilitar o entendimento, estas nomenclaturas foram adotadas nas análises seguintes.

### 4.3.1 Análises de Desempenho

As cinco melhores redes retidas nos treinamentos 2 e 3 são apresentadas na Tabela 4.4 e na Tabela 4.5, respectivamente.

Tabela 4.4 - Cinco melhores redes obtidas no treinamento 2, com cinco variáveis na camada de entrada.

Nº	RNA (Treinamento 2)	Performance		Erro	
		Treinamento	Teste	Treinamento	Teste
1	MLP 5-23-1	0,999273	0,999244	0,061542	0,067186
2	MLP 5-23-1	0,999205	0,999222	0,067256	0,069174
3	MLP 5-17-1	0,99926	0,99923	0,06262	0,068425
4	MLP 5-23-1	0,999195	0,999224	0,068104	0,06899
5	MLP 5-25-1	0,999236	0,999255	0,064649	0,066232

Tabela 4.5 - Cinco melhores redes obtidas no treinamento 3, com cinco variáveis na camada de entrada.

Nº	RNA (Treinamento 3)	Performance		Erro	
		Treinamento	Teste	Treinamento	Teste
1	MLP 5-25-1	0,999312	0,999273	0,058293	0,064551
2	MLP 5-23-1	0,999283	0,999302	0,060699	0,06211
3	MLP 5-25-1	0,999313	0,999319	0,058125	0,060593
4	MLP 5-24-1	0,999303	0,999308	0,058961	0,06153
5	MLP 5-23-1	0,999345	0,999347	0,055409	0,058086

Assim, as melhores redes obtidas em cada treinamento foram avaliadas segundo o método de seleção definido e utilizado anteriormente (redes que possuem os maiores valores de performance de treinamento e de teste e o menor valor de erro de teste). Logo, a Tabela 4.6 compara as melhores redes obtidas em cada treinamento, as quais são provenientes das Tabelas 4.4 e 4.5.

Ressalta-se que as funções de ativação do treinamento 2 e 3 são as mesmas da rede MLP 6-23-1, selecionada no treinamento 1 (exponencial para a camada escondida e logística para a camada de saída).

Tabela 4.6 - Comparação dos desempenhos das RNA selecionadas em cada treinamento.

Treinamento	RNA	Performance		Erro	
		Treinamento	Teste	Treinamento	Teste
1	MLP 6-23-1	0,999233	0,999259	0,064914	0,06584700
2	MLP 5-25-1	0,999236	0,999255	0,064649	0,06623200
3	MLP 5-23-1	0,999345	0,999347	0,055409	0,05808600

Comparando as melhores redes neurais artificiais obtidas em cada treinamento (treinamentos 1, 2 e 3), verificou-se que a RNA obtida no treinamento 3 (MLP 5-23-1) apresentou melhor desempenho em relação ao apresentado pelas demais.

Esta análise comprovou que ao utilizar a estrutura da rede sem a variável TY-31 na camada de entrada, obteve-se rede com melhor capacidade preditiva, como pode ser visualizado comparando as Tabelas 4.1, 4.4 e 4.5.

#### 4.3.2 Dados Preditos versus Dados Observado

A Figura 4.13 apresenta os valores preditos em cada treinamento *versus* os valores observados (reais).

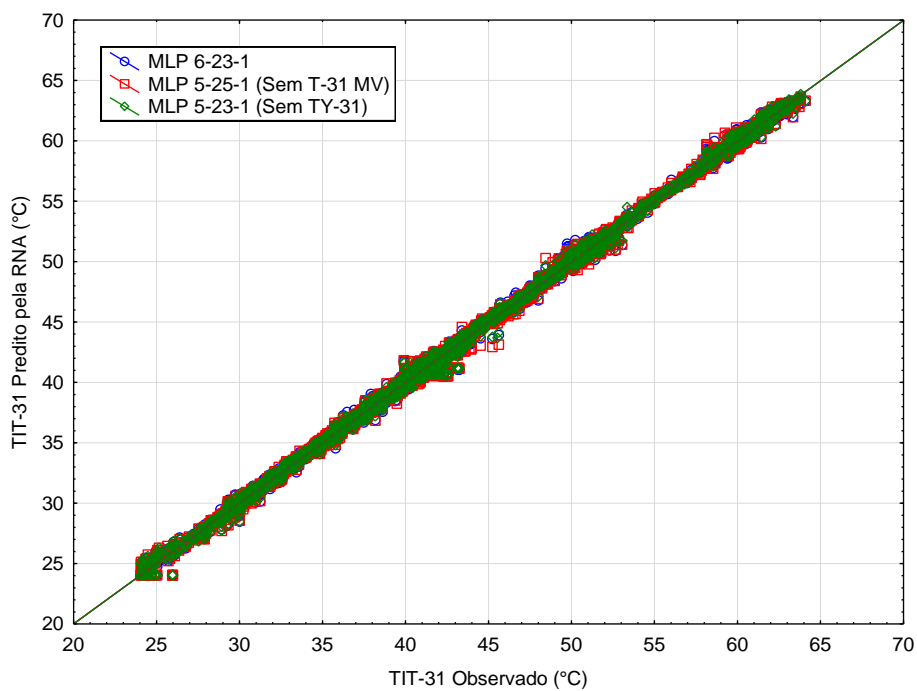


Figura 4.13 – Gráfico de probabilidade para comparação dos dados preditos em cada treinamento *versus* dados observados.

### 4.3.3 Comparação entre os Dados Experimentais e os Dados Preditos

A Figura 4.14 apresenta a comparação entre os valores preditos em cada rede com os valores observados, em cada sequência de dados.




Figura 4.14 - Temperatura do Tanque-31 versus sequência de dados. Comparação dos dados preditos em cada treinamento com os dados experimentais.

Nota-se que o desempenho das redes foi similar, não sendo notada a diferença graficamente. Neste caso, as três redes neurais artificiais apresentaram alta capacidade de representação do sistema.

### 4.3.4 Análise dos Dados Estatísticos

A Tabela 4.7 apresenta os dados estatísticos de cada rede treinada. Percebeu-se que os valores de média dos dados e desvio padrão dos dados são iguais, até a casa decimal fornecida pelo programa.

Tabela 4.7 - Dados estatísticos das redes treinadas.

Treinamento	RNA	Média dos Dados	Desvio Padrão dos Dados
1	MLP 6-23-1	46,29127479	9,24774329
2	MLP 5-25-1	46,29127479	9,24774329
3	MLP 5-23-1	46,29127479	9,24774329

#### 4.3.5 Análise de Sensibilidade

A análise de sensibilidade obtida para as três redes está representada na Tabela 4.8.

Tabela 4.8 - Comparação entre as análises de sensibilidade para as três diferentes estruturas de RNA treinadas.

Treinamento	RNA	T-30 (°C)	LIT-31 (%)	FIT-31 (L/h)	T-31 MV (%)	T-31 D (°C)	TY-31 (mA)
1	MLP 6-23-1	225,01	457,36	171,59	29,88	78,525	32,556
2	MLP 5-25-1	279,14	150,89	137,34	-	219,07	174,472
3	MLP 5-23-1	469,37	222,62	152,25	232,5	89,805	-

Em relação à tabela acima verificou-se que após a realização dos novos treinamentos, os valores calculados de *RATIO* para cada variável foram diferentes do primeiro treinamento. Ao analisar os treinamentos 2 e 3 verificou-se que todos os valores de *RATIO* são altos, sendo assim, não existe a necessidade de realização de um novo treinamento, pois todas as variáveis apresentaram grande importância na rede final.

#### 4.3.6 Análise Final

A RNA que melhor representou o processo de estudo apresentou 5 neurônios na camada de entrada (T-31 D, T-31 MV, T-30, LIT-31 e FIT-31), 23 neurônios na camada escondida e 1 neurônio na camada de saída (TIT-31).

A rede apresenta arquitetura de *Perceptron* de Múltiplas Camadas (MLP), com performance de treinamento igual a 0,999345 e erro de teste igual a 0,058086. Ressalta-se que a função de ativação da camada escondida constituiu da exponencial, enquanto a função logística referiu-se a camada de saída.



Dado ao grande número de conexões, os pesos e “*bias*” de cada são demonstrados na Tabela A.1, do Apêndice A.

## Capítulo 5 CONCLUSÕES

As características não lineares, presentes em diversos processos industriais, acarretam a necessidade de implementação de estruturas de controle de processos cada vez mais sofisticadas. Uma variedade de métodos clássicos para análise e síntese de controladores não lineares existem para uma classe específica de sistemas, como exemplo as técnicas de linearização e funções descritivas. Entretanto, devido à vasta diversidade de sistemas não lineares torna-se fundamental a adoção de sistemas computacionais para a realização da modelagem dos processos.

Nesta linha de abordagem, várias pesquisas na literatura estudam a aplicação de redes neurais artificiais para a modelagem de sistemas complexos. Do ponto de vista da teoria de modelagem e controle de processos, a habilidade das redes neurais artificiais em lidar com sistemas não lineares é, talvez, a mais significativa.

Neste trabalho, avaliou-se a implementação de redes neurais artificiais na representação do sistema de controle automático de temperatura de um tanque, localizado na planta didática PD3 da SMAR.

Estudou-se a dinâmica do processo, através da obtenção de todos os dados experimentais medidos na planta, em diferentes cenários. Posteriormente foram realizados os treinamentos das redes neurais artificiais. Com base nos parâmetros e dados estatísticos de cada rede treinada, verificou-se que a RNA com melhor desempenho apresentou alta capacidade para representar o processo em estudo.

Sendo assim, constatou-se a adequação da proposição de metodologia de inteligência artificial baseada em sistemas subsimbólicos para estruturação do modelo destinado à representação do comportamento dinâmico da planta didática PD3. Mesmo necessitando de utilização de grande quantidade de dados experimentais, a RNA selecionada apresenta confiança estatística adequada para ser aplicada em malha de controle a ser implementada no processo.

## **5.1** Perspectivas e Sugestões para Trabalhos Futuros

Inicialmente sugere-se obter novos conjuntos de dados experimentais para validar a rede neuronal artificial treinada e realizar novos treinamentos, considerando outras condições operacionais da planta didática PD3.

Em concordância, partindo dos resultados obtidos no presente trabalho e tendo em vista que a rede neuronal artificial obtida gera uma equação característica do sistema, propõe-se sequenciar este estudo a partir da aplicação de métodos matemáticos para obtenção de parâmetros de sintonia do controlador, que deverão ser adotados no sistema de controle de temperatura do Tanque-31. Assim, será possível avaliar o desempenho de uma estratégia de controle baseada na modelagem neuronal e ponderar a preferência do método de sintonia, a partir da comparação com os métodos clássicos.

Sugere-se também a realização do treinamento de novas redes neuronais artificiais empregando outros programas, para comparação. O MATLAB e o SCILAB, por exemplo, fornecem funções e aplicativos para a modelagem de sistemas não lineares complexos.

## REFERÊNCIAS BIBLIOGRÁFICAS

AHMED, D. F. Artificial Neural Network Control of Chemical Processes. **Eng. & Tech. Journal**, v. 32, 2014.

ANDRADE, F. D. et al. Redes Neurais Artificiais Aplicadas para o Estudo da Produção de Ácido Succínico via Processo Fermentativo. **Joaçaba**, 10, jan./ dez. 2010. 27-42.

BARR, A.; FEIGENBAUM, E. A. **The Handbook of Artificial Intelligence**. Los Altos: William Kaufmann, INC, 1981. Disponível em: <<https://archive.org/stream/handbookofartific01barr#page/6/mode/2up>>. Acesso em: 18 abr. 2015.

BAUGHMAN, D. R.; LIU, Y. A. **Neural Networks in Bioprocessing and Chemical Engineering**. San Diego: Academic Press, INC, 1995.

BOTTO, L.; CASSIOLATO, C. Quebrando o muro que separa a empresa da escola. **SMAR Didática**, 2012. Disponível em: <<http://www.smar.com/brasil/artigo-tecnico/smar-didatica>>. Acesso em: 04 abr. 2015.

BRAGA, A. D. P.; CARVALHO, A. P. D. L. F. D.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2ª. ed. Rio de Janeiro: LTC, 2011.

CANEPPELE, F. L.; SERAPHIM, O. J. Aplicação da Teoria Fuzzy no Controle de Sistemas de Geração de Energias Alternativas. **Energia na Agricultura**, Botucatu, v. 25, p. 24-41, 2010. Disponível em: <<http://revistas.fca.unesp.br/index.php/energia/article/view/64/45>>. Acesso em: 20 jun. 2015.

CPDEE. **Evolução dos Sistemas de Controle**, 2002. Disponível em: <<http://www.cpdee.ufmg.br/~seixas/PaginaII/Download/DownloadFiles/HistoriaControladores.PDF>>. Acesso em: 21 abr. 2015.

DE ARAÚJO, F. M. U. **Controle Inteligente**. Universidade Federal do Rio Grande do Norte. Natal. 2004.

DE SOUZA JR., M. B. **Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos**. Universidade Federal do Rio de Janeiro. Rio de Janeiro. 1993.

FERRARI, A. C. K. **Controlador PID Sintonizado por Redes Neurais Artificiais**. Universidade Federal do Paraná. Curitiba, p. 63. 2010.

FONSECA, E. F. **Controle preditivo baseado em redes neurais de fermentação alcoólica contínua**. Universidade Federal de Pernambuco. Recife. 1998.

GAUSHELL, D. J. **Supervisory Control and Data Acquisition**. [S.l.]: Proceedings of the IEEE, v. 75, 1987.

HAYKIN, S. **Redes Neurais - Princípios e Práticas**. 2<sup>a</sup>. ed. Porto Alegre: Bookman, 2001.

LAGES, W. F. **Controle Adaptativo de Sistemas Estocásticos**. Universidade Federal do Rio Grande do Sul. Rio Grande do Sul. 2007.

LINHARES, L. L. S.; JÚNIOR, J. M. A.; ARAÚJO, F. M. U. **Redes Neurais Artificiais para Identificação da Fração Molar de Pentano na Composição do GLP**, Natal, 2007.

LUQUE, J. C. C. **Controle Robusto Multivariável para um Veículo Submersível Autônomo**. Universidade de São Paulo. São Paulo. 2007.

LUYBEN, W. L. Simple method for tuning SISO controllers in multivariable systems. **Industrial & Engineering Chemistry Process Design and Development**, 25, n. 3, 1986. 654-660.

MELAZZI, F. A.; SILVA, A. R.; RAMIREZ, N. I. B. **Sistema de Migração de Dados para o Controle de Processos**. Universidade Federal Fluminense. Niterói. 2015.

MENDES, A. J. B. **Modelagem híbrido-neuronal da produção de lipase por Candida rugosa**. Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2005.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. 5ª. ed. Rio de Janeiro: LTC - Livros Técnicos e Científicos Editora Ltda, 2013.

RAMÍREZ, N. I. B. Professores UFF. **Controle de Processos - EQ**, 2012. Disponível em: <<http://www.professores.uff.br/controldeprocessos-eq/>>. Acesso em: 11 Abr. 2015.

RIBEIRO, S. R. A. Comparação entre Classificações com Rede Neural Artificial em Diferentes Áreas de Estudo. **Mercator : Revista de Geografia da UFC**, Fortaleza, 12, jan./ abr. 2013. 159-168. Disponível em: <<http://www.mercator.ufc.br/index.php/mercator/article/viewFile/643/461>>. Acesso em: 25 abr. 2015.

ROSA, G. M.; LUZ, J. A. M. D. Simulação de Moagem Mista por Rede Neural Artificial. **Rem: Revista Escola de Minas**, Ouro Preto, 65, abr./ jun. 2012. 247-256. Disponível em: <[http://www.scielo.br/scielo.php?pid=S0370-44672012000200014&script=sci\\_arttext](http://www.scielo.br/scielo.php?pid=S0370-44672012000200014&script=sci_arttext)>. Acesso em: 25 abr. 2015.

SEBORG, D. E. et al. **Process Dynamics and Control**. 3ª. ed. [S.l.]: Wiley, 2010.

SMAR. **Manual da Planta Didática - PD3**. [S.l.].

SMITH, C. A.; CORRIPIO, A. B. **Princípios e Prática do Controle Automático de Processo**. 3ª. ed. [S.l.]: LTC, 2008.

STATSOFT. **Redes Neurais**. [S.l.]. 2015. Curso de Redes Neurais Artificiais.

STATSOFT, INC. **STATISTICA V. 12**. [S.l.]: [s.n.], 2013.

TROFINO, A. **Controle Robusto**. Universidade Federal de Santa Catarina. Florianópolis. 2000.

VIEIRA, R. C.; ROISENBERG, M. **Redes Neurais Artificiais: Um Breve Tutorial**, Florianópolis.

## APÊNDICE A - PARÂMETROS DA RNA FINAL

A Tabela A.1 apresenta os parâmetros (pesos e “*bias*”) de cada conexão da rede MLP 5-23-1. Onde “*hidden neuron*” constitui o neurônio na camada escondida e “*input bias*” o “*bias*” aplicado em cada neurônios.

Tabela A.1 - Pesos e “*bias*” de cada conexão da rede MLP 6-23-1.

Conexões da MPL 5-23-1	Pesos	Conexões da MPL 5-23-1	Pesos
T-31 SP (°C) - <i>hidden neuron</i> 1	9,14	T-31 MV (%) - <i>hidden neuron</i> 17	1,23
T-31 MV (%) - <i>hidden neuron</i> 1	-10,46	LI-31 (%) - <i>hidden neuron</i> 17	-18,26
LI-31 (%) - <i>hidden neuron</i> 1	-12,35	FI-31 (L/h) - <i>hidden neuron</i> 17	3,80
FI-31 (L/h) - <i>hidden neuron</i> 1	-4,37	T-30 (°C) - <i>hidden neuron</i> 17	9,59
T-30 (°C) - <i>hidden neuron</i> 1	-8,00	T-31 SP (°C) - <i>hidden neuron</i> 18	-0,35
T-31 SP (°C) - <i>hidden neuron</i> 2	-6,59	T-31 MV (%) - <i>hidden neuron</i> 18	0,22
T-31 MV (%) - <i>hidden neuron</i> 2	-1,19	LI-31 (%) - <i>hidden neuron</i> 18	-0,61
LI-31 (%) - <i>hidden neuron</i> 2	-0,09	FI-31 (L/h) - <i>hidden neuron</i> 18	0,51
FI-31 (L/h) - <i>hidden neuron</i> 2	-5,09	T-30 (°C) - <i>hidden neuron</i> 18	-2,00
T-30 (°C) - <i>hidden neuron</i> 2	-1,03	T-31 SP (°C) - <i>hidden neuron</i> 19	-15,36
T-31 SP (°C) - <i>hidden neuron</i> 3	-7,46	T-31 MV (%) - <i>hidden neuron</i> 19	1,00
T-31 MV (%) - <i>hidden neuron</i> 3	-5,20	LI-31 (%) - <i>hidden neuron</i> 19	-8,56
LI-31 (%) - <i>hidden neuron</i> 3	1,08	FI-31 (L/h) - <i>hidden neuron</i> 19	-3,91
FI-31 (L/h) - <i>hidden neuron</i> 3	-10,83	T-30 (°C) - <i>hidden neuron</i> 19	-9,59
T-30 (°C) - <i>hidden neuron</i> 3	3,69	T-31 SP (°C) - <i>hidden neuron</i> 20	4,26
T-31 SP (°C) - <i>hidden neuron</i> 4	7,40	T-31 MV (%) - <i>hidden neuron</i> 20	1,74
T-31 MV (%) - <i>hidden neuron</i> 4	6,58	LI-31 (%) - <i>hidden neuron</i> 20	0,95
LI-31 (%) - <i>hidden neuron</i> 4	1,12	FI-31 (L/h) - <i>hidden neuron</i> 20	-6,09
FI-31 (L/h) - <i>hidden neuron</i> 4	-5,19	T-30 (°C) - <i>hidden neuron</i> 20	1,74
T-30 (°C) - <i>hidden neuron</i> 4	2,28	T-31 SP (°C) - <i>hidden neuron</i> 21	1,00
T-31 SP (°C) - <i>hidden neuron</i> 5	7,59	T-31 MV (%) - <i>hidden neuron</i> 21	-4,73
T-31 MV (%) - <i>hidden neuron</i> 5	-9,82	LI-31 (%) - <i>hidden neuron</i> 21	-13,21
LI-31 (%) - <i>hidden neuron</i> 5	-30,71	FI-31 (L/h) - <i>hidden neuron</i> 21	-6,94
FI-31 (L/h) - <i>hidden neuron</i> 5	7,93	T-30 (°C) - <i>hidden neuron</i> 21	1,38

<b>Conexões da MPL 5-23-1</b>	<b>Pesos</b>	<b>Conexões da MPL 5-23-1</b>	<b>Pesos</b>
T-30 (°C) - <i>hidden neuron 5</i>	-15,39	T-31 SP (°C) - <i>hidden neuron 22</i>	-16,42
T-31 SP (°C) - <i>hidden neuron 6</i>	-4,61	T-31 MV (%) - <i>hidden neuron 22</i>	1,05
T-31 MV (%) - <i>hidden neuron 6</i>	0,75	LI-31 (%) - <i>hidden neuron 22</i>	-6,92
LI-31 (%) - <i>hidden neuron 6</i>	-2,32	FI-31 (L/h) - <i>hidden neuron 22</i>	-1,98
FI-31 (L/h) - <i>hidden neuron 6</i>	-0,03	T-30 (°C) - <i>hidden neuron 22</i>	2,02
T-30 (°C) - <i>hidden neuron 6</i>	9,38	T-31 SP (°C) - <i>hidden neuron 23</i>	0,47
T-31 SP (°C) - <i>hidden neuron 7</i>	-13,41	T-31 MV (%) - <i>hidden neuron 23</i>	0,13
T-31 MV (%) - <i>hidden neuron 7</i>	1,12	LI-31 (%) - <i>hidden neuron 23</i>	4,15
LI-31 (%) - <i>hidden neuron 7</i>	-3,89	FI-31 (L/h) - <i>hidden neuron 23</i>	-15,92
FI-31 (L/h) - <i>hidden neuron 7</i>	0,21	T-30 (°C) - <i>hidden neuron 23</i>	4,32
T-30 (°C) - <i>hidden neuron 7</i>	12,88	<i>input bias - hidden neuron 1</i>	1,28
T-31 SP (°C) - <i>hidden neuron 8</i>	-11,34	<i>input bias - hidden neuron 2</i>	3,69
T-31 MV (%) - <i>hidden neuron 8</i>	0,46	<i>input bias - hidden neuron 3</i>	3,86
LI-31 (%) - <i>hidden neuron 8</i>	-2,60	<i>input bias - hidden neuron 4</i>	-15,89
FI-31 (L/h) - <i>hidden neuron 8</i>	-5,74	<i>input bias - hidden neuron 5</i>	10,06
T-30 (°C) - <i>hidden neuron 8</i>	-4,26	<i>input bias - hidden neuron 6</i>	-4,64
T-31 SP (°C) - <i>hidden neuron 9</i>	-4,31	<i>input bias - hidden neuron 7</i>	6,55
T-31 MV (%) - <i>hidden neuron 9</i>	1,33	<i>input bias - hidden neuron 8</i>	10,91
LI-31 (%) - <i>hidden neuron 9</i>	-5,82	<i>input bias - hidden neuron 9</i>	6,62
FI-31 (L/h) - <i>hidden neuron 9</i>	0,48	<i>input bias - hidden neuron 10</i>	-3,55
T-30 (°C) - <i>hidden neuron 9</i>	-4,67	<i>input bias - hidden neuron 11</i>	-0,62
T-31 SP (°C) - <i>hidden neuron 10</i>	-1,04	<i>input bias - hidden neuron 12</i>	-1,41
T-31 MV (%) - <i>hidden neuron 10</i>	-2,32	<i>input bias - hidden neuron 13</i>	1,08
LI-31 (%) - <i>hidden neuron 10</i>	2,17	<i>input bias - hidden neuron 14</i>	3,39
FI-31 (L/h) - <i>hidden neuron 10</i>	-0,04	<i>input bias - hidden neuron 15</i>	11,64
T-30 (°C) - <i>hidden neuron 10</i>	-3,67	<i>input bias - hidden neuron 16</i>	8,10
T-31 SP (°C) - <i>hidden neuron 11</i>	-0,01	<i>input bias - hidden neuron 17</i>	12,74
T-31 MV (%) - <i>hidden neuron 11</i>	0,15	<i>input bias - hidden neuron 18</i>	3,34
LI-31 (%) - <i>hidden neuron 11</i>	-0,03	<i>input bias - hidden neuron 19</i>	16,40
FI-31 (L/h) - <i>hidden neuron 11</i>	0,21	<i>input bias - hidden neuron 20</i>	-3,88



<b>Conexões da MPL 5-23-1</b>	<b>Pesos</b>	<b>Conexões da MPL 5-23-1</b>	<b>Pesos</b>
T-30 (°C) - <i>hidden neuron 11</i>	0,93	<i>input bias - hidden neuron 21</i>	-5,96
T-31 SP (°C) - <i>hidden neuron 12</i>	3,64	<i>input bias - hidden neuron 22</i>	8,74
T-31 MV (%) - <i>hidden neuron 12</i>	-9,25	<i>input bias - hidden neuron 23</i>	-7,08
LI-31 (%) - <i>hidden neuron 12</i>	-17,35	<i>hidden neuron 1 - TIC-31 (°C)</i>	-0,06
FI-31 (L/h) - <i>hidden neuron 12</i>	-1,91	<i>hidden neuron 2 - TIC-31 (°C)</i>	-2,63
T-30 (°C) - <i>hidden neuron 12</i>	-8,05	<i>hidden neuron 3 - TIC-31 (°C)</i>	0,12
T-31 SP (°C) - <i>hidden neuron 13</i>	-5,73	<i>hidden neuron 4 - TIC-31 (°C)</i>	1,97
T-31 MV (%) - <i>hidden neuron 13</i>	0,49	<i>hidden neuron 5 - TIC-31 (°C)</i>	0,03
LI-31 (%) - <i>hidden neuron 13</i>	3,95	<i>hidden neuron 6 - TIC-31 (°C)</i>	3,34
FI-31 (L/h) - <i>hidden neuron 13</i>	-8,95	<i>hidden neuron 7 - TIC-31 (°C)</i>	-0,01
T-30 (°C) - <i>hidden neuron 13</i>	0,47	<i>hidden neuron 8 - TIC-31 (°C)</i>	1,38
T-31 SP (°C) - <i>hidden neuron 14</i>	-2,38	<i>hidden neuron 9 - TIC-31 (°C)</i>	0,26
T-31 MV (%) - <i>hidden neuron 14</i>	-0,51	<i>hidden neuron 10 - TIC-31 (°C)</i>	-6,84
LI-31 (%) - <i>hidden neuron 14</i>	-0,54	<i>hidden neuron 11 - TIC-31 (°C)</i>	1,43
FI-31 (L/h) - <i>hidden neuron 14</i>	-0,41	<i>hidden neuron 12 - TIC-31 (°C)</i>	9,11
T-30 (°C) - <i>hidden neuron 14</i>	-32,74	<i>hidden neuron 13 - TIC-31 (°C)</i>	-1,71
T-31 SP (°C) - <i>hidden neuron 15</i>	-16,59	<i>hidden neuron 14 - TIC-31 (°C)</i>	-5,13
T-31 MV (%) - <i>hidden neuron 15</i>	-2,49	<i>hidden neuron 15 - TIC-31 (°C)</i>	-4,81
LI-31 (%) - <i>hidden neuron 15</i>	0,04	<i>hidden neuron 16 - TIC-31 (°C)</i>	1,77
FI-31 (L/h) - <i>hidden neuron 15</i>	-0,74	<i>hidden neuron 17 - TIC-31 (°C)</i>	0,15
T-30 (°C) - <i>hidden neuron 15</i>	-14,20	<i>hidden neuron 18 - TIC-31 (°C)</i>	-0,12
T-31 SP (°C) - <i>hidden neuron 16</i>	-3,98	<i>hidden neuron 19 - TIC-31 (°C)</i>	-2,90
T-31 MV (%) - <i>hidden neuron 16</i>	-4,06	<i>hidden neuron 20 - TIC-31 (°C)</i>	-0,05
LI-31 (%) - <i>hidden neuron 16</i>	0,60	<i>hidden neuron 21 - TIC-31 (°C)</i>	2,07
FI-31 (L/h) - <i>hidden neuron 16</i>	-6,06	<i>hidden neuron 22 - TIC-31 (°C)</i>	-6,40
T-30 (°C) - <i>hidden neuron 16</i>	-25,37	<i>hidden neuron 23 - TIC-31 (°C)</i>	9,00
T-31 SP (°C) - <i>hidden neuron 17</i>	-20,15	<i>hidden bias - TIC-31 (°C)</i>	-0,35