

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA QUÍMICA

**ÁREA DE CONCENTRAÇÃO:
DESENVOLVIMENTO DE PROCESSOS QUÍMICOS**

**Integração de Processos em Tempo
Real para Monitoramento e Controle:
Aplicação para Planta de PET**

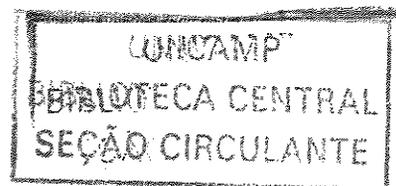
AUTOR: JOÃO CARLOS BASTOS GONZAGA

ORIENTADOR: PROF. DR. RUBENS MACIEL FILHO

**TESE DE MESTRADO APRESENTADA À FACULDADE DE ENGENHARIA
QUÍMICA COMO PARTE DOS REQUISITOS EXIGIDOS PARA A OBTENÇÃO
DO TÍTULO DE MESTRE EM ENGENHARIA QUÍMICA.**

CAMPINAS – SÃO PAULO

OUTUBRO DE 2003



UNIDADE PL
Nº CHAMADA II/Unicamp
G589i
V _____ EX _____
TOMBO BCI 57649
PROC 16-117-04
C _____ D α
PREÇO 11,00
DATA 16/04/2004
Nº CPD _____

CNO019670E-6

Bib id: 314779

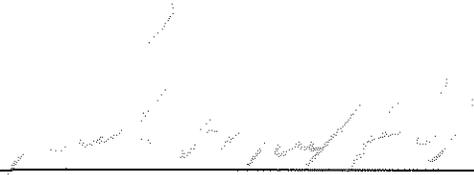
FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

G589i Gonzaga, João Carlos Bastos
Integração de processos em tempo real para
monitoramento e controle: aplicação para planta de PET
/ João Carlos Bastos Gonzaga. --Campinas, SP: [s.n.],
2003.

Orientador: Rubens Maciel Filho
Dissertação (mestrado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Química.

1. Polimerização. 2. Redes neurais (Computação). 3.
Viscosidade. I. Maciel Filho, Rubens. II. Universidade
Estadual de Campinas. Faculdade de Engenharia
Química. III. Título.

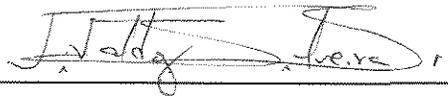
Tese de Mestrado defendida por JOÃO CARLOS BASTOS GONZAGA e aprovada em 06 de outubro de 2003 pela banca examinadora constituída pelos doutores:



Prof. Dr. Rubens Maciel Filho (Orientador)

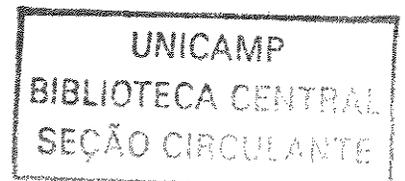


Prof. Dr. Galo A. Carrillo Le Roux / USP

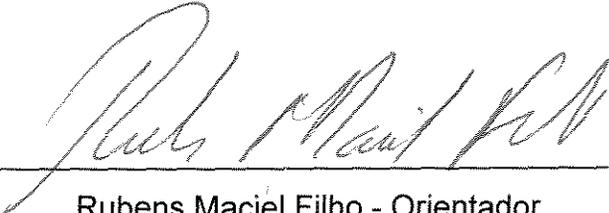


Prof. Dr. Vivaldo Silveira Junior / FEA

200405275



Este exemplar corresponde à versão final da Dissertação de Mestrado em Engenharia Química defendida por João Carlos Bastos Gonzaga em 06 de Outubro de 2003.



Rubens Maciel Filho - Orientador

À Maria José, minha mulher, pela amizade, compreensão, carinho e amor.

Aos meus filhos, João Carlos (Joãozinho) e Marina. Dois grandes presentes de Deus.

Ao Luiz Gonzaga (*in memoriam*), meu pai, que foi uma lição de vida, uma referência de dignidade e de amor.

À Maria Tereza, minha mãe, que tem sido a minha luz e minha consciência.

AGRADECIMENTOS

À Deus, pois se não fosse da sua vontade nada disso seria possível.

Ao Prof. Dr. Rubens Maciel Filho pela orientação, incentivo e apoio, tornando possível a realização deste trabalho. Além disso agradeço a oportunidade de uma saudável amizade, que nos permitiu não só o engrandecimento cultural, mas também um crescimento pessoal e profissional.

À banca examinadora pelas correções e sugestões fornecidas.

À M&G/ Rhodia-ster que me permitiu esta qualificação profissional.

Ao Eng. José Carlos da Rocha Mendes, gerente do departamento de engenharia da M&G/ Rhodia-ster unidade de Poços de Caldas, pelo incentivo e apoio.

Ao amigo Maurício Magalhães, engenheiro de produção da M&G/ Rhodia-ster unidade de Poços de Caldas, pelo auxílio na correção inicial e pelas sugestões na elaboração do capítulo 3.

Ao amigo Dr. Alessandro Mattedi pelo auxílio na correção e sugestões enriquecedoras que possibilitaram concluir com êxito esta tarefa.

Ao amigo Dr. Luiz Augusto C. Meleiro pela generosidade em autorizar o uso de algumas de suas anotações e me auxiliar durante todo o trabalho com ricas informações.

Ao amigo Dr. Chang Kiang pela idéia do projeto, pelo auxílio na identificação das variáveis para treinamento da RNA.

Aos amigos Adilson Cata Preta, Eduardo Coselli, Flávio Pereira, João Carlos Rosa, Kalen Silva, Marco Aurélio de Carvalho, Marcos Guerra, Mylene A C Ferreira, Pedro Giordano, Silvana Barbosa e Wander Rehder que, de várias maneiras, contribuíram no desenvolvimento deste trabalho.

Aos professores da Unicamp pelo excelente nível de suas aulas que me possibilitaram um grande aprendizado.

SUMÁRIO

1 – Introdução.....	1
1.1 - Motivações para o projeto	1
1.2 – Objetivos	1
1.3 – Organização da tese	2
2 - Revisão Bibliográfica	4
3 - Descrição do Processo.....	9
3.1 - Processo Rhodia-Ster	9
3.2 - Polimerização Líquida.....	10
3.2.1) Alimentação de Pasta	10
3.2.2) Esterificação Primária.....	14
3.2.3) Esterificação Secundária	17
3.2.4) Baixa Polimerização	21
3.2.5) Alta Polimerização.....	25
3.2.6) Extrusão e Corte.....	34
3.3 - Variáveis para Treinamento da Rede Neural.....	34
3.4 - Conclusões.....	36
4 - Arquitetura do Sistema Digital de Controle.....	37
4.1 – Introdução.....	37

4.2 - Sistema Digital de Controle Distribuído (SDCD).....	37
4.3 - Controlador Lógico Programável.....	38
4.3.1) Pontos de Saída.....	40
4.3.1.1) Especificação de Módulos de Entrada e Saída.....	40
4.3.1.2) Aspectos relevantes na escolha de um CLP.....	41
4.4 - (IHM) - Sistema de Supervisão.....	44
4.4.1- Setcim	44
4.4.2- Tarefa Externa (<i>External Task</i>).....	45
4.5- Topologia de Rede do Sistema de Supervisão e Controle.....	48
4.6 – Conclusões.....	50
5 - Desenvolvimento do Soft-Sensor.....	51
5.1 - Introdução.....	51
5.2 - O Que é o Modelo, no Que Se Baseia e Quais São os Algoritmos Utilizados.....	51
5.2.1) <i>Soft-Sensors</i>	52
5.2.2) Redes Neurais Artificiais.....	53
5.2.2.1) Motivação para a Utilização de Redes Neurais Artificiais.....	56
5.2.2.2) O Modelo Matemático do “Multilayer Perceptron” (<i>MLP</i>).....	57
5.2.2.3) Processos de Aprendizado.....	59
5.2.2.4) O Treinamento do “Multilayer Perceptron” (<i>MLP</i>).....	62
5.2.2.5) O Algoritmo Backpropagation.....	64
5.2.2.6) A Regra Delta Generalizada.....	66

5.3 - Descrição do Procedimento e dos Critérios.....	71
5.3.1) Coleta e separação de dados de processo.....	71
5.3.2) Configuração da rede.....	72
5.3.3) Treinamento das redes neurais.....	73
5.3.4) Testes <i>off-line</i>	74
5.4 - Implantação do Modelo e Acompanhamento.....	74
5.4.1) Utilizando a MLP.....	74
5.4.2) Testes <i>on-line</i> e Integração ao Ambiente de Produção.....	75
5.5 - Integração com o “Setcim”.....	76
5.5.1) Descrição do funcionamento da Integração com Setcim.....	76
5.6 – Conclusões.....	80
6 - Resultados do Trabalho.....	81
6.1 - Geração da base de dados.....	81
6.2 - Treinamento da RNA.....	81
6.3 - Implementação do <i>soft-sensor</i> para controlar a planta.....	87
6.4 – Conclusões.....	91
7 Sistema de Controle.....	92
7.1 - Controlador Proporcional-Integrativo-Derivativo.....	92
7.2 - Metodologia de Sintonia de Controle PID.....	93
7.3 – Resultados.....	95
7.4 – Conclusões.....	101

8 - Conclusões Gerais & Trabalhos Futuros.....	102
Referências Bibliográficas.....	104
Apêndice A.....	110

LISTA DE FIGURAS

Figura 3.1 -Visão geral da Planta na fase líquida.....	10
Figura 3.2 - Sistema de Alimentação de Pasta.....	13
Figura 3.3 - Fluxograma da Esterificação.....	16
Figura 3.4 - Esquema da fase de esterificação (EP e ES).....	18
Figura 3.5 - Fluxograma da Esterificação Secundária.....	20
Figura 3.6 - Fluxograma Baixa Polimerização.....	23
Figura 3.7 - Esquema da fase de polimerização.....	25
Figura 3.8 - Fluxograma Alta Polimerização.....	27
Figura 3.9 - Bloco Viscosímetro.....	31
Figura 3.10 - Esquema do princípio de medida da viscosidade.....	32
Figura 3.11 - Sensibilidade da viscosidade obtida através de um simulador de processo desenvolvido na empresa.....	35
Figura 3.12 - Sensibilidade da viscosidade obtida através de um simulador de processo desenvolvido na empresa.....	35
Figura 4.1 - Linguagem de programação Ladder.....	39
Figura 4.2 - Diagrama de Blocos de um CLP.....	42
Figura 4.3 - CPU de um CLP da Allen Bradley.....	43
Figura 4.4 - Interface de entrada e saída (Cartões do CLP).....	43
Figura 4.5 - Coluna de um painel do CLP.....	43
Figura 4.6 - Painel do CLP de uma Linha de Produção.....	43
Figura 4.7 - Diagrama de Blocos da Malha de Controle da Viscosidade.....	44
Figura 4.8 - Fluxo da Lógica de uma Tarefa Externa do Setcim.....	46
Figura 4.9 - Relação de uma Definição de Registro e uma Tarefa Externa	47
Figura 4.10 - Topologia de Rede.....	49
Figura 5.1 - Analogias entre os neurônios biológico e matemático.....	53
Figura 5.2 – Esquema de unidade McCulloch – Pitts.....	54
Figura 5.3 – RNA típica (4 entradas, n neurônios escondidos e 3 saídas).....	55
Figura 5.4 – O neurônio artificial.....	58
Figura 5.5 – Perceptron Multi Camada do tipo “ <i>Feedforward</i> ”.....	59
Figura 5.6 – A Regra Delta.....	61
Figura 5.7 – Esquema de treinamento do <i>Perceptron</i>	62

Figura 5.8 – Exemplos de funções de ativação dos neurônios da camada interna.....	62
Figura 5.9 – Esquema de treinamento backpropagation.....	64
Figura 5.10 – Exemplo de superfície de erro.....	65
Figura 5.11 – Conexão dos neurônios i e j	66
Figura 5.12 - Rede MLP com três camadas.....	70
Figura 5.13 - Utilização da rede MLP.....	74
Figura 5.14 - Integração do Soft-Sensor com o Setcim.....	76
Figura 5.15 - Estrutura do Record Sens-X.....	78
Figura 5.16 - Estrutura do Record SVT-5.1E.....	79
Figura 5.17 - Esquema do sensor virtual.....	80
Figura 6.1 - Viscosímetro versus Soft-Sensor.....	83
Figura 6.2 - “Zoom” da Figura 6.1.....	83
Figura 6.3 - Gráfico de dispersão.....	84
Figura 6.4 - Erro simples.....	84
Figura 6.5 - Erro Absoluto.....	85
Figura 6.6 - Erro Relativo.....	85
Figura 6.7 - Viscosímetro versus Soft-Sensor – Tempo Real.....	86
Figura 6.8 - Gráfico de dispersão – Tempo Real.....	86
Figura 6.9 - Erro Absoluto - Medida Tempo Real.....	87
Figura 6.10 - Fluxograma da lógica implementada para utilização do Soft-Sensor.....	89
Figura 6.11 - Linha de Produção Controlada Pelo Soft-Sensor.....	90
Figura 6.12 - Laboratório versus Soft-Sensor	90
Figura 7.1 - Degrau de 7% na saída da válvula de controle de vácuo em malha aberta.....	96
Figura 7.2 - Função de transferência do vácuo do Alto Polimerizador.....	96
Figura 7.3 - Vácuo <i>versus</i> viscosidade antes da sintonia.....	98
Figura 7.4 - Vácuo <i>versus</i> viscosidade após sintonia.....	98
Figura 7.5 - Sintonia das Temperaturas da Coluna do EP.....	99
Figura 7.6 - Situação dos controladores quanto ao modo de operação.....	100
Figura 7.7 - Situação dos controladores instalados na empresa, quanto ao valor de saída.....	100
Figura 7.8 - Tipos de controladores utilizados na empresa.....	101
Figura 7.9 - Funcionamento dos controladores.....	101
Figura A.1 - Diagrama de blocos de malha fechada.....	112

LISTA DE TABELAS

Tabela 3.1 - Dados de Bases.....	11
Tabela 3.2 - Principais variáveis do EP	17
Tabela 3.3 - Principais variáveis do ES	19
Tabela 3.4 - Principais variáveis do BP.....	22
Tabela 3.5 - Principais variáveis do AP	28
Tabela 3.6 - Influência da variação das variáveis de processo na qualidade da resina.....	30
Tabela 3.7 - Variáveis para treinamento Rede Neural.....	34
Tabela 7.1 - Breve histórico de controladores PID.....	93
Tabela 7.2 - Regra de sintonia de Ziegler-Nichols para uma excitação em degrau.....	97
Tabela A.1 - Diferenças entre as equações ISA e AB	110

RESUMO

Integração de Processos em Tempo Real para Monitoramento e Controle: Aplicação para Planta de PET

Esta dissertação apresenta a implementação de um sensor virtual (*soft-sensor*) para um processo industrial de polimerização PET -Poli (Tereftalato de Etileno), baseando-se em redes neurais (RNA). O sensor atua como medidor redundante da viscosidade do polímero na fase líquida; e, no caso de falhas mecânicas, propicia um diagnóstico de falhas do viscosímetro físico e substituição do mesmo no monitoramento do sistema de controle.

O controle da viscosidade é executado por meio de dois controladores PID (Proporcional-Integrativo-Derivativo) em configuração cascata, sendo o controlador da viscosidade o mestre e o controlador de vácuo do alto polimerizador o escravo, que manipula a válvula de quebra-vácuo.

O uso de redes neurais nesta dissertação é uma metodologia bastante adequada tendo-se em vista as complexidades cinéticas relacionadas aos sistemas poliméricos. Neste presente trabalho, foi utilizado o algoritmo de retropropagação com apenas uma camada intermediária (*hidden*) para uma rede do tipo *feedforward*. O algoritmo do *soft-sensor* foi implementado em um sistema supervisorio (SETCIM-Aspentech), onde um banco de dados é atualizado em tempo real. O sistema supervisorio é executado em um servidor Alpha-Server 1000, que está interconectado com CLP's (controladores lógicos programáveis).

Todos os dados no Setcim são organizados em unidades fundamentais (*Record*). As aplicações podem ler ou escrever dados que usem (entre outras opções) uma rica Interface de Programação de Aplicações (API - *Application Programming Interfaces*), suportado por Serviços de Chamadas Remotas a Procedimentos (RPC- *Remote Procedure Call*). Isto propiciou o desenvolvimento de diversos *soft-sensors*, para diferentes unidades de forma simultânea.

A implementação do *soft-sensor* para o controle da viscosidade foi realizada através de solicitações de ensaios, com a participação de todos os setores da fábrica envolvidos na qualidade do produto. Um algoritmo de restrições foi desenvolvido no CLP para garantir a

segurança do processo enquanto o *soft-sensor* estiver funcionando como estimador *on-line* no controle da viscosidade.

A utilização de sensor virtual como estimador de variável de processo para controle possibilita um controle robusto e ainda permite, no caso de ocorrência de algum distúrbio sobre a variável controlada, a identificação das variáveis causadoras de tal variação. O sucesso dos resultados foi constatado por engenheiros da planta industrial após o acompanhamento de testes *on-line* do sensor virtual. Atualmente, o *soft-sensor* opera como estimador da viscosidade no controle de uma linha de produção com um desempenho excelente.

Palavras-chave: polimerização, rede neural, Soft-sensor, viscosidade.

ABSTRACT

Real Time Process Integrating for Monitoring and Control: PET Plant Application

This work deals with the implementation of a soft-sensor for a PET (Polyethylene terephthalate) industrial process based on neural networks. The soft-sensor acts as redundant measure current for the polymer viscosity in the liquid phase; and, in case of mechanical faults, it is able to diagnoses the faults on the viscometer and can replace it.

The viscosity control is realized through to two Proportional-Integral-Derivative (PID) controllers in cascade configuration. The viscosity controller is the master and vacuum controller of the high polymerizer is the slave, manipulating the vacuum valve.

The use of neural network in this work is suitable due to kinetic complexities related to polymeric system. In this paper, it was employed the retro-propagation algorithm with only an intermediary layer for a feed-forward net. The soft-sensor algorithm was implemented in the supervisory system (SETCIM-Aspentech), where the database is actualized in real time. The supervisory system is executed in a Alpha-Server 1000, that is interconnected with PLC's (Programmable Logic Controllers).

All data in the Setcim are organized in fundamental units (records). The applications are able to read and write data that use (among other options) one rich Application Programming Interfaces (API), supported by Remote Procedure Call (RPC). This became possible the development of several soft-sensors.

The soft-sensor implementation for viscosity control was realized through requisitions of experiments with the participation of all the factory sectors related to product quality. An algorithm of restrictions was developed in the PLC, for assure the process safety, while the soft-sensor is controlling the viscosity.

The use of a soft-sensor as process variable estimator for controllers is an interesting strategy; it assures a robust control and, in the presence of some disturbance, identifies which the process variables sensitize such variation. Process engineering group verified this conclusion after the attendance of on-line tests using the soft-sensor. Nowadays, the soft-sensor operates as viscosity estimator in the control of one production plant line with excellent results.

KEY WORDS: neural network, PET process, polymerization process, Soft-sensor, viscosity,

CAPÍTULO 1

INTRODUÇÃO

1.1 - Motivações para o projeto

Os processos de polimerização são caracterizados por dinâmicas complexas e desconhecidas. Esta complexidade está relacionada ao mecanismo cinético de polímeros bem como aspectos de fluidodinâmica e fenômenos de transporte (Chan e Nascimento, 1994). Dentro deste contexto e levando-se em consideração todas as experiências de muitos anos de sintonia de controladores de retro-alimentação (*feedback*) Proporcional-Integrativo-Derivativo (PID) das linhas de produção de resina PET e implementações de sistemas de controle multivariáveis, as complexidades dinâmicas de monitoração e controle relacionadas às não-linearidades do processo evidenciaram-se significativamente.

Baseando-se nas experiências industriais descritas anteriormente, evidenciou-se a importância do desenvolvimento de um sistema de monitoração da viscosidade do produto para as etapas de avaliação da qualidade do produto. A metodologia adotada neste presente trabalho para o desenvolvimento do soft-sensor é a teoria de redes neurais artificiais (RNA).

Normalmente, quando a teoria de sistemas lineares não apresenta bons resultados para aproximação de funções multivariáveis, identificação de sistemas e controle de sistemas dinâmicos, opta-se por métodos de sistemas não lineares, tais como redes neurais artificiais (RNA). As características das redes neurais artificiais devem-se principalmente à sua capacidade de representação de comportamentos não lineares arbitrários, que são bem adequados as aplicações desta dissertação.

1.2 – Objetivos

Assim sendo, esta dissertação aborda a implementação de um sensor virtual (*soft-sensor*), utilizando RNA, para atuar como um medidor redundante da viscosidade e, no caso de possíveis falhas, ter como função principal detectar falhas do sensor físico e substituí-lo no monitoramento do sistema de controle.

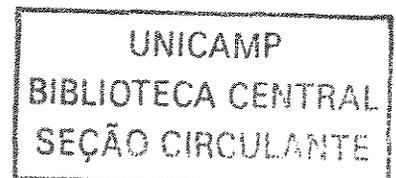
A utilização da rede neural neste trabalho pode ser justificada pelas dificuldades relacionadas aos modelos cinéticos complexos de sistemas poliméricos. Neste trabalho, utilizou-se o algoritmo de retropropagação com apenas uma camada intermediária (*hidden*) para uma rede do tipo *feedforward*.

A opção pelo desenvolvimento de um *soft-sensor* para modelar a viscosidade foi motivada pela existência de um banco de dados históricos do departamento de engenharia de manutenção. Os dados são caracterizados por um razoável número de intervenções no medidor e um tempo de reparo associado relativamente longo. Isto se deve à dependência, às vezes, da parada de fábrica ou da dificuldade de encontrar peças sobressalentes, fazendo com que o controle do produto se limitasse a uma medida indireta através da corrente do motor do agitador, que nem sempre era uma medida confiável e, também, aumentando a frequência de análises do laboratório, que apesar de serem confiáveis, sempre chegam com um certo atraso.

1.3 – Organização da tese

O capítulo 1 apresenta, de maneira geral, as motivações e os objetivos desta dissertação. No capítulo 2, procura-se mostrar as principais referências bibliográficas relacionadas ao uso de RNA e desenvolvimentos de *soft-sensors*. No capítulo 3, é apresentado o processo de produção contínua da resina PET da Rhodia-Ster - Polimerização Líquida. Procura-se propiciar uma visão geral da planta por meio de uma descrição de todas as etapas do processo. Além disso, devido à importância da viscosidade, alguns comentários são descritos de relações da mesma com outras variáveis das etapas do sistema. Por fim, uma descrição sucinta do funcionamento de um viscosímetro em linha com o processo é apresentada. No capítulo 4, é apresentado o Sistema Digital de Controle (SDC) adotado (da planta da Rhodia-Ster de Poços de Caldas.). O objetivo deste capítulo é propiciar uma visão geral da topologia de rede do sistema de supervisão e controle, descrevendo de forma sucinta cada parte do sistema e, por fim, mostrar o monitoramento da viscosidade no sistema. No capítulo 5, são descritos os procedimentos necessários para a implementação de um Sensor Virtual ("*Soft-Sensor*") utilizado para a predição da viscosidade em reatores de polimerização. No capítulo 6 são apresentados os resultados do trabalho. Uma análise do rendimento e produtividade também é realizada. No capítulo 7, são descritas algumas

técnicas de controle de processo usando algoritmos PID. Por fim, no último capítulo apresentam-se as conclusões finais e sugestões para os trabalhos futuros.



CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

O capítulo da revisão bibliográfica foi estruturado de forma a apresentar alguns trabalhos em literatura, que abordam sensores virtuais, em especial os que utilizam redes neurais artificiais e dar uma visão geral da evolução da aplicação de RNA em indústrias químicas.

A operação adequada de um processo industrial necessita de um sistema confiável de monitoramento de variáveis. As variáveis significativas do processo no tocante à caracterização do produto precisam ser mantidas em faixas de operação restritas ou valores desejados (*set-points*) que assegurem a qualidade do produto; para tanto, deve existir um sistema de controle que, a partir de medições provenientes de sensores, assegure o controle de variáveis relacionadas. No caso de falhas mecânicas e/ou eletrônicas, deve haver um sistema que, a partir de medições provenientes de sensores, diagnostique as possíveis falhas existentes. Através da melhoria de desempenho operacional do processo industrial é possível assegurar um produto mais competitivo de maior qualidade e menor custo, haja visto a existência de um mercado altamente competitivo.

Entretanto, existem alguns desafios relacionados ao sistema de monitoramento, tais como: inacessibilidade *on-line* de medição e alto custo de sensores. Além disso, medições podem não ser confiáveis trazendo transtornos para a operação do processo.

Uma alternativa largamente empregada nos últimos anos em processos industriais é o uso de *softwares* que funcionam como estimadores de variáveis, denominados de *soft-sensors* ou *software sensor*. Segundo MARTIN (1997) já existiam mais de 1000 instalações de *soft-sensors* em processos industriais, comprovando assim a grande importância e eficiência de tais *softwares*.

O desenvolvimento desses *soft-sensors* têm sido largamente possibilitado pelo grande avanço tecnológico de circuitos integrados ocorrido nas últimas décadas; pois através de processadores sofisticados de alta velocidade e memórias de alta capacidade,

torna-se possível o desenvolvimento de algoritmos complexos de estimação de variáveis que tratam um número elevado de dados de forma mais robusta.

Os *soft-sensors* são algoritmos que realizam inferência de propriedades através de modelos matemáticos. Estes modelos podem ser obtidos através de princípios físicos (caixa branca) ou de dados empíricos ou industriais (caixa preta). A modelagem caixa branca requer conhecimentos das leis físicas do processo e por isso pode despende muito tempo e esforço. Para a modelagem caixa preta são necessários dados de entrada e saída do sistema e uma representação matemática linear ou não linear das variáveis envolvidas. Outra abordagem de modelagem muito interessante é associação dos dois tipos (caixa branca e caixa preta), denominados de modelos híbridos. Um exemplo disso é o desenvolvimento de um modelo através de leis físicas e a determinação de seus parâmetros por meio de uma modelagem caixa preta.

O filtro de Kalman, WILSON et al. (1998), que tem sido largamente aplicado, é um exemplo de estimador que considera ruídos de medida e modelo do processo para inferir variáveis do processo. O Filtro de Kalman foi inicialmente empregado para sistemas lineares, sendo depois estendido para sistemas não lineares (EKF - *Extended Kalman Filter*), tais como processos de polimerização e biotecnológicos, ZYNGIER et al. (2001).

Como exemplo excelente de estimadores caixa preta, apresenta-se as redes neurais. Devido a complexidade estrutural das mesmas, torna-se possível estabelecer correlações altamente não lineares entre as variáveis de entrada e saída do processo, de modo que capacita representar uma larga variedade de processos.

A seguir um breve histórico de redes neurais é descrito:

As idéias iniciais dos estudos de redes neurais surgiram com os trabalhos de MCCULLOCH e PITTS (1943), em que sugeriram a construção de uma máquina baseada ou inspirada no cérebro humano. HEBB (1949) traduziu matematicamente a sinapse dos neurônios biológicos. MINSKI (1951) constrói o Snark, primeiro neurocomputador com capacidade de aprendizado, ou seja, ajustava automaticamente os pesos entre as sinapses. Não executou nenhuma função útil. Em 1956 no "Dartmouth College" surgiram os dois

paradigmas da Inteligência Artificial, a simbólica e o conexionista. A Inteligência Artificial Simbólica procura simular o comportamento inteligente humano desconsiderando os mecanismos responsáveis por tal. Já a Inteligência Artificial Conexionista acredita que construindo-se um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros. ROSENBLATT (1957) concebeu o *perceptron*, que era uma rede neural de duas camadas, usado no reconhecimento de caracteres. O primeiro neuro computador a obter sucesso (Mark I Perceptron) surgiu em 1957 e 1958, criado por Frank Rosenblatt, Charles Wightman e outros. Devido a profundidade de seus estudos, suas contribuições técnicas e de sua maneira moderna de pensar, muitos o vêem como o fundador da neuro computação na forma em que a temos hoje. Seu interesse inicial para a criação do *Perceptron* era o reconhecimento de padrões. Após Rosenblatt, Bernard Widrow, com a ajuda de alguns estudantes, desenvolveram um novo tipo de elemento de processamento de redes neurais chamado de *Adaline*, equipado com uma poderosa lei de aprendizado, que diferente do Perceptron ainda permanece em uso. Widrow também fundou a primeira companhia de hardware de neurocomputadores e componentes. WIDROW (1962) desenvolveu um processador para redes neurais.

O período de 1967 a 1982 foi uma época de pouca contribuição para o meio científico devido excessivos trabalhos publicados e a falta de resultados concretos, que na época era demasiadamente esperado por parte de pesquisadores "entusiasmados" com a teoria de redes neurais. Entretanto, a partir da década de 80, publicações de grande contribuição científica foram retomadas de desenvolvimento de redes neurais.

A seguir algumas explicações são descritas em relação às redes neurais:

Redes neurais artificiais podem ser definidas como estruturas computacionais projetadas a fim de simular os princípios organizacionais existentes nos sistemas neurais biológicos. Por sua natureza, o estudo de redes neurais é multidisciplinar, envolvendo pesquisadores de diversas áreas, como neurofisiologia, psicologia, física, computação e engenharia, HAYKIN (1999).

Uma RNA típica é composta por uma densa rede de elementos processadores (neurônios artificiais), não lineares, dispostos em camadas e interconectados através de canais unidirecionais – as conexões – análogos às sinapses de um neurônio biológico SOUZA JR. (1993).

A rede torna-se capaz de processar eficientemente dados numéricos, produzindo sinais de saída a partir de dados de entrada, após uma etapa chamada de treinamento, onde a RNA é submetida a diversos padrões com dados similares de entrada e saída. No treinamento (às vezes chamados de aprendizagem), os pesos e “biases” da rede são modificados.

Existem muitas aplicações na literatura de *soft-sensors* baseados em redes neurais em engenharia química. A seguir, algumas dessas aplicações são sucintamente explicitadas:

ZYNGIER et al. (2001) propuseram duas abordagens de *soft-sensor* aplicado a processo de tratamento de água; o primeiro baseado no uso de um modelo simplificado do processo e uma rede neural *feedforward*; ao passo que o segundo baseado em uma rede neural do tipo DSNN (*Dynamically Stacked Neural Networks*).

MELEIRO & MACIEL FILHO (2000) desenvolveram um controlador adaptativo multivariável empregando um *soft-sensor* como estimador de três variáveis de saída de um processo biotecnológico; este *software* foi obtido através de uma modelagem híbrida - modelagem fenomenológica e redes neurais. O desempenho do *soft-sensor* acoplado ao controlador foi excelente possibilitando a operação do sistema com altos níveis de produtividade.

RÉGNIER et al. (1996) aplicaram um controlador preditivo adaptativo para reatores químicos batelada e semi-batelada usando um *soft-sensor*, obtido através de redes neurais, para estimar a taxa de produção de calor químico.

ASSIS & MACIEL FILHO (2000) estudaram *soft-sensor* aplicado a um bioreator para estimação *on-line* de variáveis usando técnicas de filtragem, tais como: filtro de Kalman estendido, observadores adaptativos e redes neurais. A abordagem baseada em

redes neurais é mais fácil de ser implementada e pode tratar de forma mais adequada não-linearidades e com dados ruidosos.

SCHMIDT & MÄHLING (2001) descreveram uma classificação de modelagem de sistemas e empregaram um *soft-sensor* baseado em redes neurais para um processo de poliolefinas.

Entretanto, apesar do grande potencial de aplicação, notam-se poucos trabalhos na literatura de aplicação de *soft-sensor* em processos de polimerização. Tais processos são caracterizados por comportamentos altamente não lineares e imprecisos. Pode-se citar o trabalho de CHAN e NASCIMENTO (1994) que utilizaram redes neurais artificiais para modelar o processo de polimerização de olefinas em reatores tubulares a altas pressões. Dados industriais foram utilizados no treinamento da rede para prever os perfis de temperatura e das propriedades do polímero ao longo do reator. A utilização da rede neural neste estudo deve-se a dificuldade de se desenvolver modelos cinéticos precisos de sistemas poliméricos, especialmente a altas pressões e temperaturas.

Neste contexto, devido à necessidade de trabalhos de aplicação de *soft-sensors* em processos de polimerização, apresenta-se esta dissertação que mostra a utilização de um *soft-sensor* para estimar a viscosidade em tempo real dos reatores de polimerização, proporcionando uma leitura alternativa e robusta da viscosidade. No capítulo 5 uma revisão mais completa é apresentada.

CAPÍTULO 3

DESCRIÇÃO DO PROCESSO

Neste capítulo é apresentado o processo de produção contínua da resina PET da Rhodia-Ster - Polimerização Líquida. O objetivo é dar uma visão geral da planta por meio de uma descrição de todas as etapas do processo. Além disso, devido a importância da viscosidade, alguns comentários são tecidos de relações da mesma com outras variáveis das etapas do sistema. Por fim, uma descrição sucinta de funcionamento de um viscosímetro em linha com o processo é apresentada.

3.1 Processo Rhodia-Ster

A Rhodia-Ster possui plantas de produção de resina PET -Poli (Tereftalato de Etileno), também conhecido como Polietileno Tereftalato ou poliéster, em Poços de Caldas (MG).

O processo Rhodia-ster de polimerização para produção da resina PET para embalagens é caracterizado por ser um processo totalmente automatizado, controlado via CLP (Controlador Lógico Programável), sendo que a interface com a operação é feita através de um Sistema de Supervisão da Aspentech (SETCIM 4.9).

O processo de produção da resina PET é realizado em duas etapas:

- 1) polimerização líquida;
- 2) polimerização no estado sólido;

A tecnologia da primeira etapa (polimerização líquida) foi desenvolvida dentro da Rhodia-Ster no Site de Poços de Caldas. A Polimerização de estado sólido (SSP - *Solid State Polymerization*) é proveniente de fornecedores de equipamentos para este fim (Buhler e a Hosokawa-Bepex). O Site de Poços possui plantas de SSP com as duas tecnologias, sendo que a planta mais nova e de maior capacidade funciona com a tecnologia Buhler.

As primeiras plantas contínuas de PET de alta capacidade de produção foram projetadas no início da década de 90. Em 1994 operavam com capacidade nominal de 60 kt/ano, e após um desgargalamento realizado em 1997, passaram a operar a 80 kt/ano. Estas plantas, as mais antigas, usam a tecnologia Bepex nos SSP's.

Em 1995, a Rhodia-Ster realizou o projeto de uma nova planta que partiu em 1996 com a produção de 90 kt/ano e atualmente opera com 105 kt/ano. A figura 3.1 mostra uma visão geral da planta na fase líquida. A tecnologia de obtenção da resina PET na fase líquida é descrita a seguir:

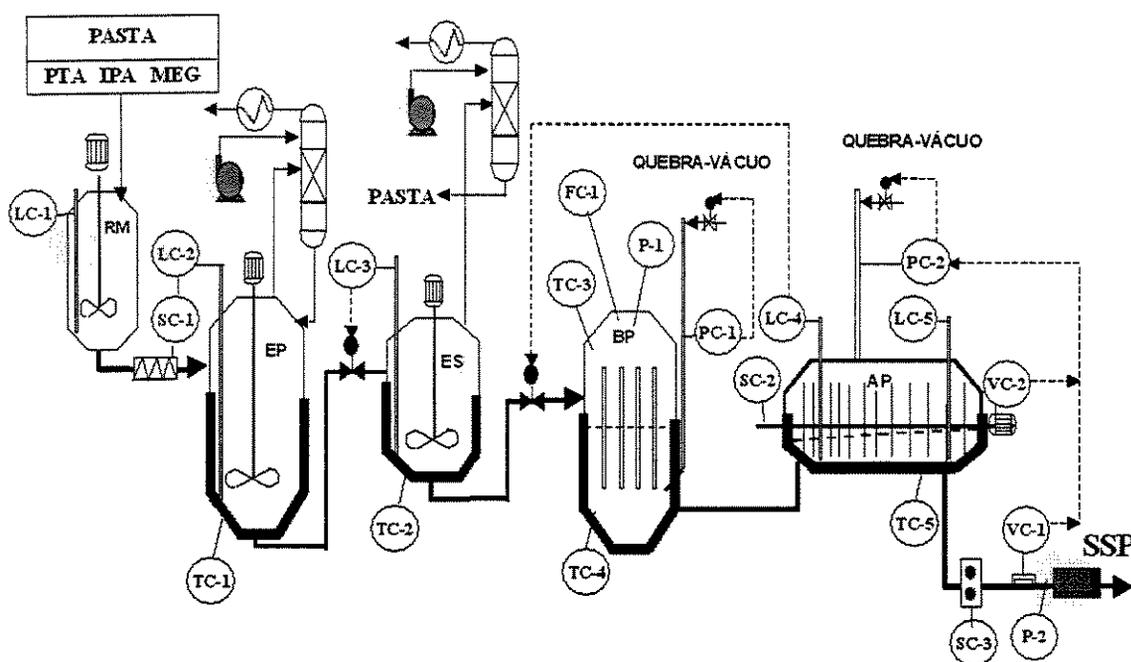


Figura 3.1 Visão geral da Planta na fase líquida.

RM (Tanque de Razão Molar), EP (Esterificador Primário), ES (Esterificador Secundário), BP (Baixo Polimerizador), AP (Alto Polimerizador), LC (Controlador de Nível), P (Indicador de Pressão), PC (Controlador de Pressão), TC (Controlador de Temperatura), SC (Controlador de Velocidade), VC (Controlador de Viscosidade)

A Polimerização Líquida é um processo contínuo de produção do polímero poliéster amorfo. É um processo que envolve as reações químicas de esterificação e polimerização, TREMBLAY (1999). Estas reações ocorrem no interior de quatro reatores (dois esterificadores e dois polimerizadores). É um processo contínuo a partir de etileno glicol (EG), ácido tereftálico purificado (PTA) e ácido isoftálico purificado (IPA), onde os subprodutos gerados são água, glicol e sólidos. O processo é dividido nas seguintes fases:

- Alimentação de Pasta
- Esterificação Primária
- Esterificação Secundária
- Baixa Polimerização
- Alta Polimerização
- Extrusão e Corte

Serão descritas com detalhes a seguir.

3.2.1 Alimentação de Pasta

Esta etapa do processo compreende a alimentação contínua de matérias primas(monoetileno glicol (MEG), ácido tereftálico purificado (PTA) e ácido isoftálico purificado (IPA)) misturadas numa pasta em proporções preestabelecidas definidas por uma razão molar (RM- equação 3.1), definida como a razão entre o número de moles de monoetileno glicol (MEG) e o número de moles de ácido tereftálico purificado (PTA) e ácido isoftálico purificado (IPA).

$$RM = \frac{\text{moles.MEG}}{\text{moles.(PTA + IPA)}} = \frac{\frac{\text{massa.MEG}}{\text{MM.MEG}}}{\frac{\text{massa.(PTA + IPA)}}{\text{MM.(PTA + IPA)}}} = \frac{166}{62} \times \frac{\text{massa.MEG}}{\text{massa.(PTA + IPA)}} \quad (3.1)$$

Tabela 3.1 - Dados de Bases

	MM	Formula
PTA	166,1370	C8H6O4
IPA	166,1370	C8H6O4
MEG	62,0700	C2H6O2
DEG	106,1240	C4H10O3
ÁGUA	18,0153	H2O
PTA (IPA) + MEG	192,1760	(C10H8O4) _n
PTA (IPA) + DEG	236,2310	(C12H12O5) _n

Para ocorrer a reação de esterificação, deve existir uma razão molar de MEG e PTA (ou IPA) igual a dois. Porém no processo Rhodia-Ster o valor empregado para essa variável é menor que dois. Alguns fatores contribuem para isso em processos industriais e são citados a seguir:

- 1- Manutenção da qualidade do monômero e polímero em relação as características dimensionais e operacionais dos equipamentos (temperaturas, pressão, tempo residência);
- 2- Paralelamente à esterificação, ocorre a reação de polimerização que gera EG como produto, que é consumido pela esterificação;
- 3- Economia de processo;

Descrição do Processo

O início de fabricação da resina ocorre no sistema de alimentação de pasta. Estudos realizados preliminarmente mostraram a importância desta fase e a sua considerável influência sobre a viscosidade final do produto.

A dosagem da matéria prima é feita em função da razão molar especificada. Células de carga são utilizadas nos silos de IPA, PTA e no tanque de MEG, para enviar sinais ao CLP, onde existe uma lógica de controle para parar a alimentação de cada produto quando atingido o valor especificado.

Após abastecido o tanque de MEG e os silos de PTA e IPA, o material é enviado para betoneira, que funciona como misturador; que periodicamente habilita o descarregamento para o tanque de razão molar (conforme indicado na figura 3.1).

O tanque de razão molar tem a função de servir de pulmão de pasta para o processo contínuo, considerando que a preparação de pasta é feita em batelada. É útil também para homogeneizar e reduzir o taxa de variação de RM transferida ao EP.

Após o nível do tanque de RM atingir 80%, o sistema estará pronto para abastecer o Esterificador Primário (EP). A bomba BB1.2 (figura 3.1) pressuriza a linha de alimentação do EP até atingir a pressão do reator e dessa forma proporcionar a abertura da válvula de alimentação. A vazão de pasta é controlada pelo nível do EP, que atua na velocidade da BB1.2. A figura 3.2 representa o sistema de alimentação de pasta.

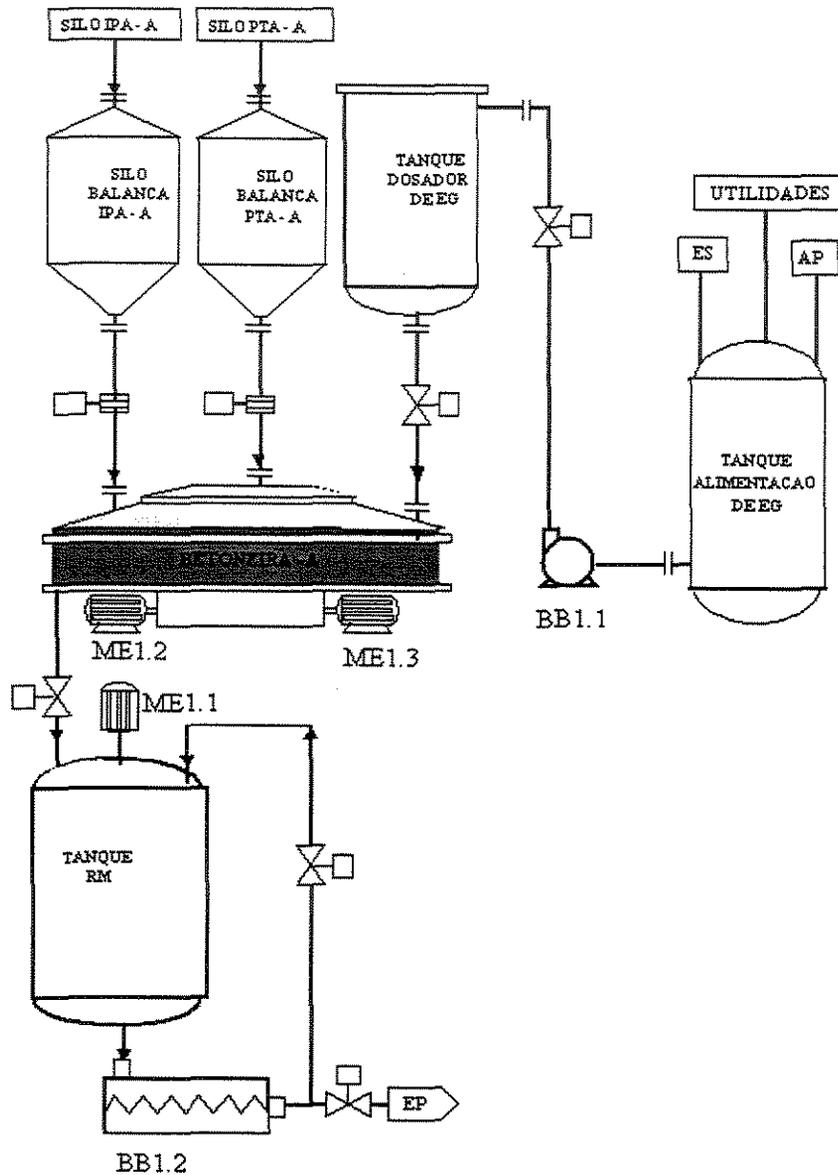


Figura 3.2 - Sistema de Alimentação de Pasta

3.2.2 Esterificação Primária

A reação química entre um álcool (MEG) e um ácido (PTA ou IPA) é denominada de esterificação. A reação ocorre sob condições específicas de pressão, temperatura, agitação e tempo de residência, formando um éster, também denominado monômero (DHET- dihidroxiethyltereftalato, no caso da reação MEG e PTA, e DHEI - dihidroxiethylisofthalato, no caso da reação MEG e IPA) e água como subproduto.

No processo de esterificação, o esterificador primário (EP) é responsável por um rendimento de 80% da reação; a análise quantitativa deste rendimento pode ser realizada por duas formas:

i) monitoração dos grupos carboxílicos finais (CEG): - COOH

Estão presentes nas moléculas do PTA e IPA na forma de radicais; com a evolução da reação de esterificação, ocorre o decremento de CEG até se atingir valores próximos de 1150eq/g, que são característicos da esterificação primária; esta monitoração é feita periodicamente pelo laboratório, através de titulação.

ii) água

Para promover a reação de esterificação no sentido de formação de monômeros, deve-se remover a água do meio. Para isso, existe uma coluna de destilação, onde a mistura de gases de MEG e água é separada através da condensação do MEG e da destilação da água. A água como subproduto da destilação corresponde a aproximadamente 12% em massa de pasta alimentada no esterificador primário (EP) e tem a seguinte proporção: 99,5 % água e 0,5% EG.

Formação de oligômeros no esterificador primário (EP):

As mesmas variáveis de processo necessárias para promover a esterificação também favorecem a reação paralela de formação de oligômeros (união de algumas moléculas de monômero). No esterificador primário (EP), a composição de oligômeros é maior entre monômeros e dímeros.

Descrição do Processo

No interior do esterificador primário (EP), a agitação da pasta é em camadas, isto é, não ocorre uma homogeneização total da massa. Isso permite um tempo de residência (dependendo do nível e da vazão) suficiente para que ocorra a reação de esterificação sem que grandes quantidades de PTA livre misturados ao monômero sejam transferidos ao esterificador secundário.

O aquecimento do reator é realizado por meio do *reboiler* do esterificador primário (EP). O TIC-2.1 é responsável por manter a temperatura em torno do valor desejado; através do envio de um sinal para a válvula de pressão na linha de fluido térmico primário (PV-2.1). O sistema de aquecimento é mantido em uma condição automática de controle, isto é, a válvula de pressão é manipulada para regular a pressão do fluido térmico do *reboiler* para garantir o controle da temperatura do esterificador primário (EP) no valor especificado. Algumas oscilações na vazão de pasta bem como o aquecimento tendem a provocar variações de pressão no interior do esterificador primário (EP); por conseguinte, alterações nas taxas de evaporação de MEG e água. No tocante ao controle automático de pressão do reator e da coluna, o PIC-2.1 envia sinais à válvula de pressão na linha de gases na saída da coluna de destilação (PV2.2), promovendo, dessa forma, o controle da pressão do reator e da coluna em valor especificado.

O Processo de Destilação

Os gases (MEG e água) que saem do esterificador primário (EP) são separados na coluna de destilação; o MEG é condensado e retornado ao EP e a água destilada é resfriada em um condensador, cai no tanque recebedor, que por *overflow*, é drenada para o esgoto (ETE). O controle de temperatura do topo da coluna de destilação é feito através do TIC-2.2, que regula a velocidade da bomba de refluxo (BB2.1). O controle de temperatura do fundo da coluna de destilação é feito através do TIC-2.3, que regula a abertura da válvula de entrada de fluido térmico no *reboiler* (FV-2.1). A tabela 3.2 mostra as principais variáveis do EP e a figura 3.3 mostra o fluxograma da esterificação primária.

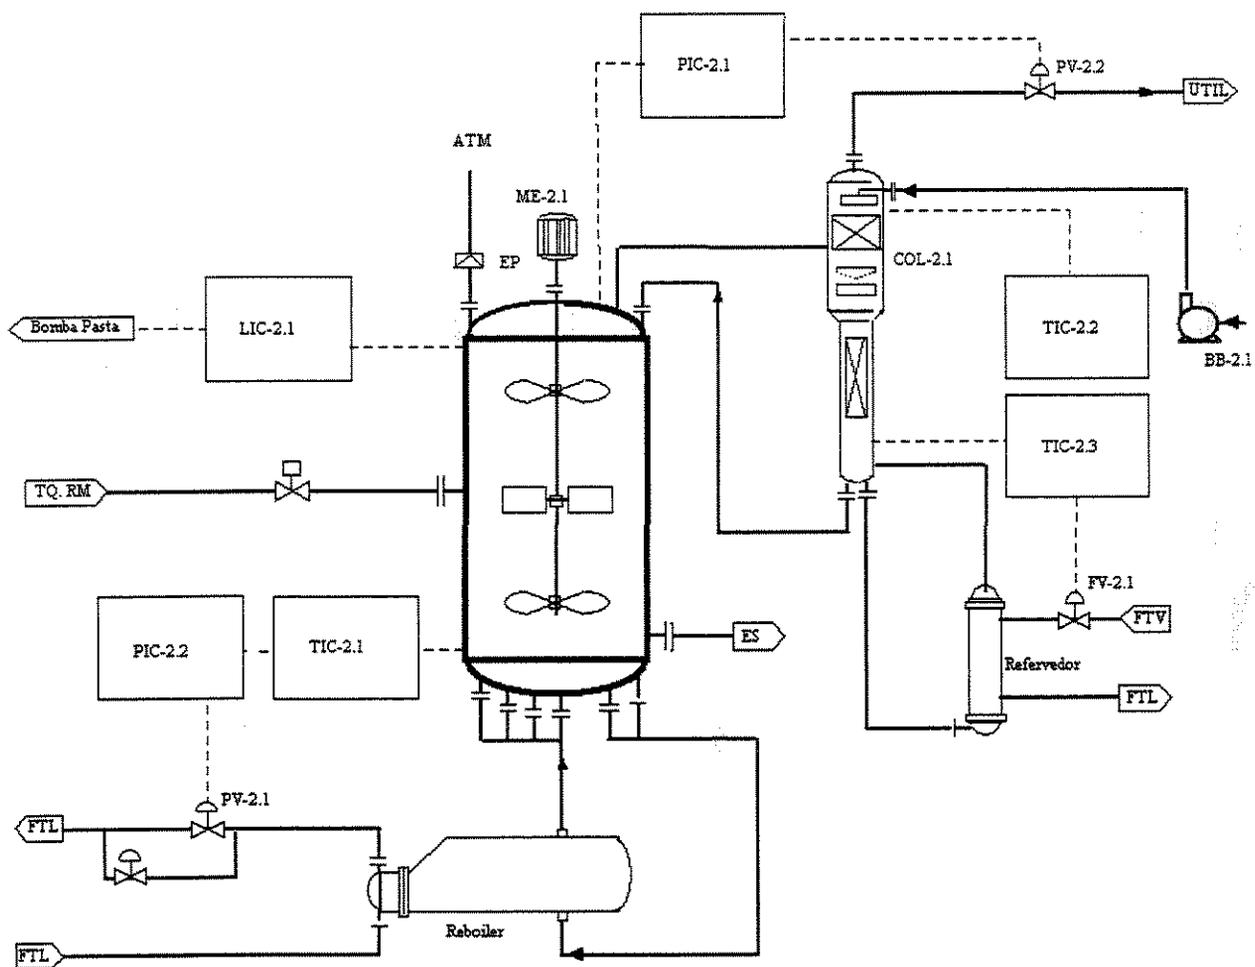


Figura 3.3- Fluxograma da Esterificação Primária

Tabela 3.2 - Principais variáveis do EP

Nome	Descrição
LIC-2.1	Controle do nível do EP (atua na bomba de pasta)
PIC-2.1	Controla a pressão do reator (0 a 7 bar)
PIC-2.2	Controla a pressão do <i>reboiler</i> (escravo da temperatura do reator-TIC-2.1)
PIC-2.3	Controla a pressão do EP (atua na válvula (PV-2.2)).
TIC-2.1	Controla a temperatura do reator(mestre para o PIC-2.2)
TIC-2.2	Controla a temperatura do topo da coluna (atua na velocidade bb. Refluxo)
TIC-2.3	Controla a temperatura do fundo da coluna (atua na válvula do <i>reboiler</i>)
COL-2.1	Coluna de destilação
BB-2.1	Bomba de refluxo
ME-2.1	Motor do agitador do EP
PV-2.1	Válvula de controle de pressão de fluido térmico <i>reboiler</i>
PV-2.2	Válvula de controle de pressão do EP
FV-2.1	Válvula de controle de fluxo de fluido térmico <i>reboiler</i>
FTV	Fluído térmico no estado vapor
FTL	Fluído térmico no estado líquido

3.2.3 Esterificação Secundária

A esterificação secundária é uma etapa de complementação da esterificação iniciada no esterificador primário (EP), possibilitando absorver flutuações do processo. A reação continua sob condições específicas de temperatura, tempo de residência e pressão atmosférica. O valor da taxa esterificação secundária é incrementado aproximadamente de 80 para 98%.

Análise do rendimento da reação:

1- CEG: (Grupos Carboxílicos finais): -COOH

Reduzido de 1150 no EP para cerca 400eq/g

2- ÁGUA

Como subproduto da esterificação secundária, o condensado apresenta a seguinte proporção: 58% água, 40% MEG e 2% sólidos.

Formação de oligômeros no esterificador secundário (ES)

No esterificador secundário (ES), a composição de oligômeros é maior entre dímeros e trímeros, chegando à composição de cerca de 25% em peso, conforme esquema representado na Figura 3.4:

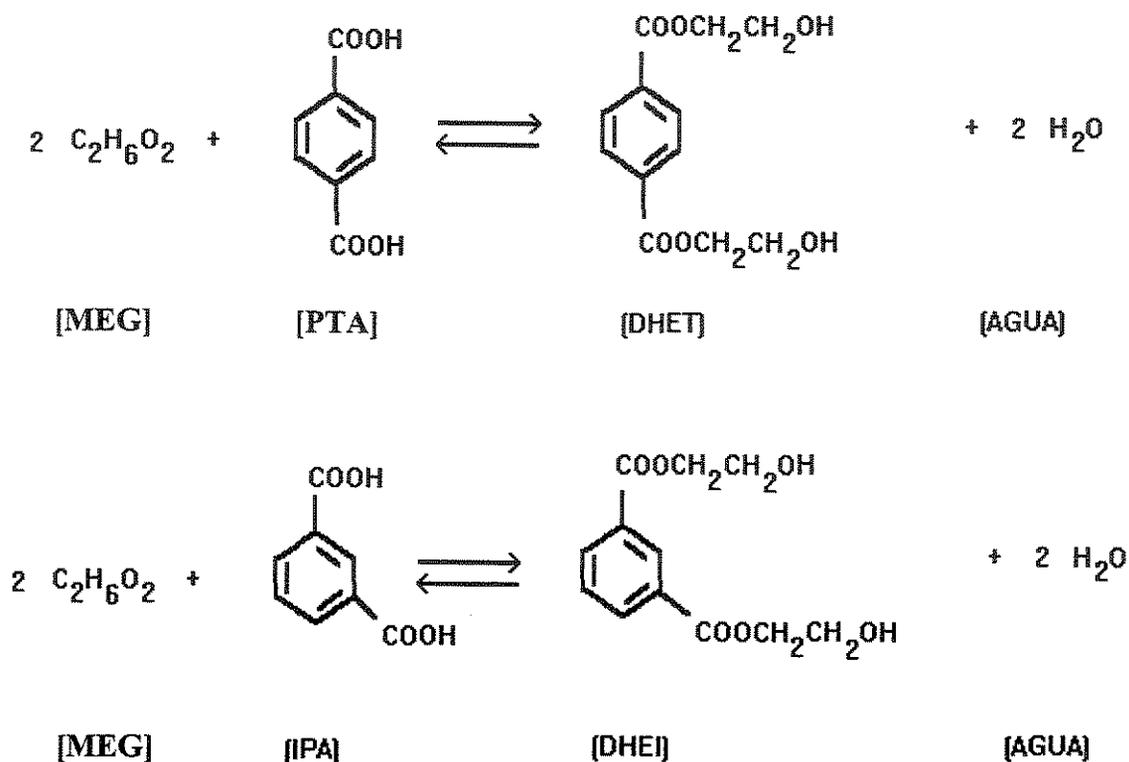


Figura 3.4 - Esquema da Fase de Esterificação

Concluída a etapa de esterificação, os monômeros DHET e DHEI reagem entre si, através da reação de policondensação, formando uma cadeia de alto peso molecular.

Descrição do Processo

O monômero obtido no esterificador primário (EP) é transferido ao esterificador secundário (ES) pela diferença de pressão (o ES opera na pressão atmosférica e o EP em uma pressão que pode variar de 0 a 7 bar). A vazão de monômero é controlada através do sinal do LIC-3.1, que opera em modo automático, controlando a abertura da LV-3.1 na linha de monômero na entrada do ES.

O aquecimento no reator é realizado através do *reboiler* do esterificador secundário (ES). O TIC-3.1 controla a temperatura em torno do valor desejado através do envio de sinais para a PV-3.1 (válvula de pressão na linha de fluido térmico primário). O sistema de aquecimento é mantido em modo automático, isto é, a PV-3.1 é regulada para manter a temperatura do ES no valor especificado.

O Processo de Destilação

Os gases (etileno glicol e água) que saem do esterificador secundário (ES) são separados na coluna de destilação; o glicol é condensado (e retornado para o tanque de EG do sistema de alimentação de pasta) e a água é destilada. O controle de temperatura do topo da coluna de destilação é realizado por meio do TIC-3.2, que regula a velocidade da bomba de refluxo (BB3.1). O controle de temperatura do fundo da coluna de destilação é realizado por meio do TIC-3.3, que regula a abertura da válvula de entrada de fluido térmico no *reboiler* (FV3.2). A tabela 3.3 mostra as principais variáveis do ES e a Figura 3.5 mostra o fluxograma da esterificação secundária.

Tabela 3.3 - Principais variáveis do ES

Nome	Descrição
LIC-3.1	Controle do nível do ES (atua na válvula de entrada do ES (LV-3.1))
PIC-3.1	Controla a pressão do <i>reboiler</i> (escravo da temperatura do reator-TIC-3.1)
TIC-3.1	Controla a temperatura do reator(mestre para o PIC-3.1)
TIC-3.2	Controla a temperatura do topo da coluna (atua na velocidade BB-3.1)
TIC-3.3	Controla a temperatura do fundo da coluna (atua na válvula FV-3.1)
BB-3.1	Bomba de refluxo
ME-3.1	Motor do agitador do ES
PV-3.1	Válvula de controle de pressão de fluido térmico <i>reboiler</i>
FV-3.1	Válvula de controle de fluxo de fluido térmico <i>reboiler</i>
FTV	Fluido térmico no estado vapor
FTL	Fluido térmico no estado líquido

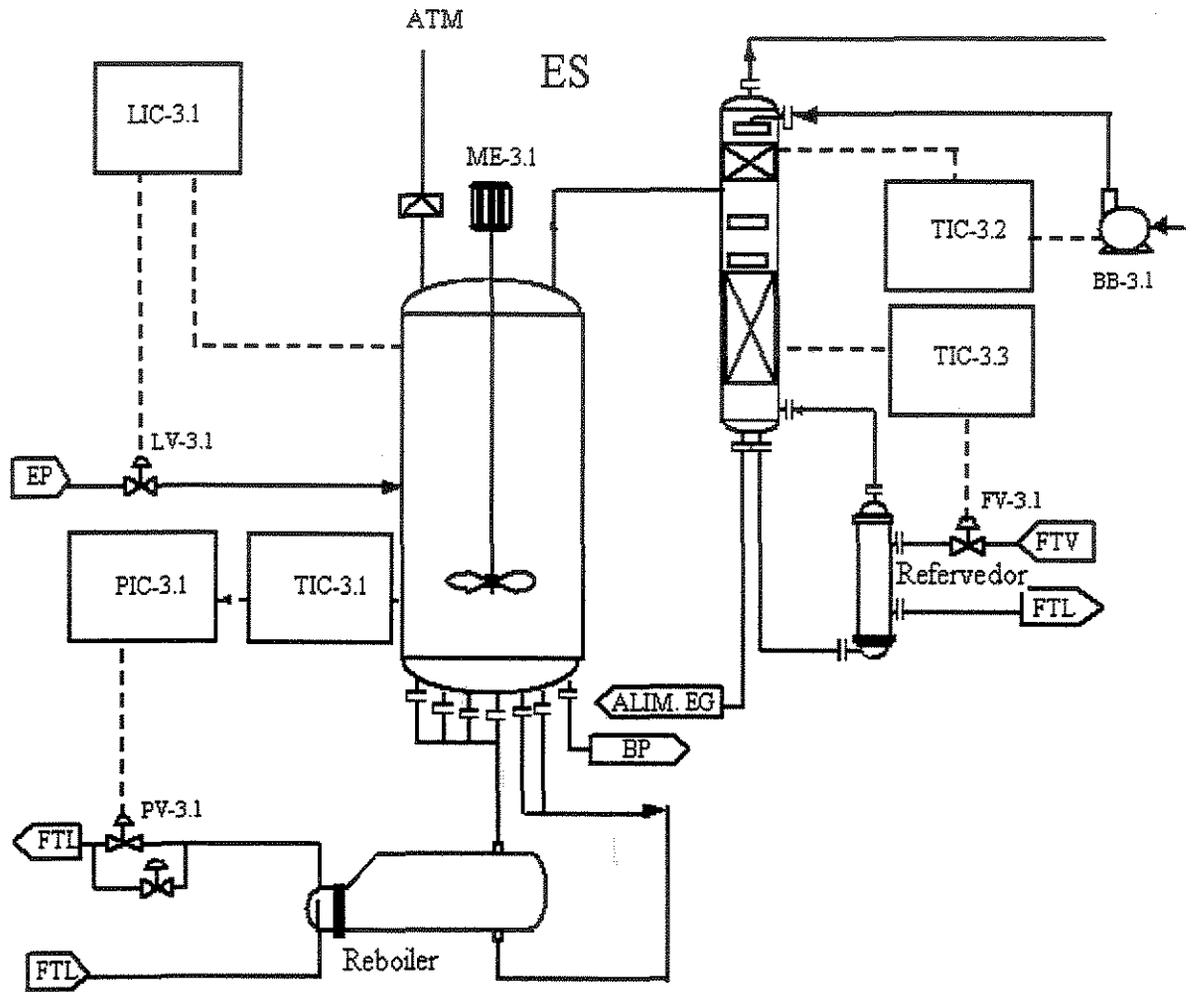


Figura 3.5- Fluxograma da Esterificação Secundária

3.2.4 Baixa Polimerização

A reação de polimerização (encadeamento dos monômeros) se inicia nesta etapa do processo e nesta etapa são adicionados os aditivos e catalisadores necessários. A partir desta etapa os reatores começam a operar sob vácuo, com objetivo de aumentar a remoção de subprodutos gerados, principalmente o MEG, favorecendo a reação no sentido de formação dos produtos.

A reação química entre as moléculas de monômeros formando uma longa cadeia molecular é denominada de polimerização. No caso específico de reações onde ocorre a formação de subprodutos além de polímero é também denominada de policondensação. A presença de mais de um tipo de monômero caracteriza a reação como sendo de Copolimerização, que é o caso do PET.

A reação de copolimerização ocorre sob condições especificadas de temperatura, vácuo, catalisador e tempo de residência. No baixo polimerizador ocorre o início da copolimerização que terá como produto o PET com cadeias de pesos moleculares da ordem de 2500 (viscosidade intrínseca aproximadamente 0,200 dl/g (decilitros por grama)) e basicamente MEG, como subproduto da reação. O subproduto é removido do processo através de ejetores, o que estabelece um equilíbrio no sentido direto da reação. A composição é aproximadamente de: 78% MEG, 17% Água, 4,5% Sólidos e 0,5% DEG.

Descrição do processo:

O monômero é transferido ao primeiro estágio do baixo polimerizador (BP) através da diferença de pressão entre o esterificador secundário (ES) e o baixo polimerizador (BP). O controle da vazão é feito através do PDIC-4.1 (diferença de pressão entre o 1º e 2º estágios do BP) que atua em LV-4.1 (válvula de nível na linha de monômero, na entrada do BP).

No primeiro estágio, o monômero inicia a reação de polimerização. O aquecimento é feito através de serpentinas internas com controle de aquecimento por meio do TIC-4.1

que comanda a abertura da PV-4.1. O vácuo é baixo no primeiro estágio, propiciando dessa forma o início da polimerização sem arraste de monômeros. Através dos *Downcomers*, o monômero em reação é transferido por *overflow* para o segundo estágio onde ocorre a fase complementar da baixa polimerização.

O aquecimento no segundo estágio é feito através de serpentinas internas e o controle é realizado por meio do TIC-4.2, que comanda abertura de PV-4.2. O vácuo no BP é condicionado por meio da linha de gases no segundo estágio, onde o polímero adquire certa viscosidade, evitando assim o arraste por parte dos ejetores.

O controle do vácuo é feito através do PIC-4.3, que atua na PV- 4.3 (válvula quebra vácuo do ejetor). O subproduto da reação no baixo polimerizador é retirado do vaso em forma de gases pelo ejetor. Os gases passam pelo condensador sob o jato de glicol dos bicos *sprays*.

O condensado é transferido para o tanque receptor, onde é filtrado em telas de abertura 0,45 mm. Parte do glicol é utilizado como refluxo para os bicos *sprays* do condensador, onde é anteriormente resfriado. O condensado restante é transferido ao tanque de drenagem (*Sump tank*) por *over flow* do tanque receptor. Posteriormente é transferido para o departamento de utilidades. A tabela 3.4 mostra as principais variáveis do BP e a figura 3.6 mostra o fluxograma baixa polimerização.

Tabela 3.4 - Principais variáveis do BP

Nome	Descrição
PDIC-4.1	Controle do nível do BP (atua na válvula de entrada do BP (LV-4.1))
LIC-5.1	Controle do nível do AP (altera <i>set-point</i> do PDIC-3.1)
TIC-4.1	Controla a temperatura primeiro estágio do BP (faz <i>set-point</i> no PIC-4.1)
TIC-4.2	Controla a temperatura segundo estágio do BP (atua na válvula PV-4.2)
PIC-4.1	Controla a temperatura primeiro estágio do BP (atua na válvula PV-4.1)
PIC-4.2	Controla a pressão do <i>reboiler</i> (atua na válvula PC-4.4)
PIC-4.3	Controla o vácuo no segundo estágio do BP (atua na válvula PV-4.3)
BB-4.1	Bomba de refluxo
PV-4.4	Válvula de controle de pressão de fluido térmico <i>reboiler</i>
TQ-4.1	Tanque receptor de glicol
FTL	Fluido térmico no estado líquido

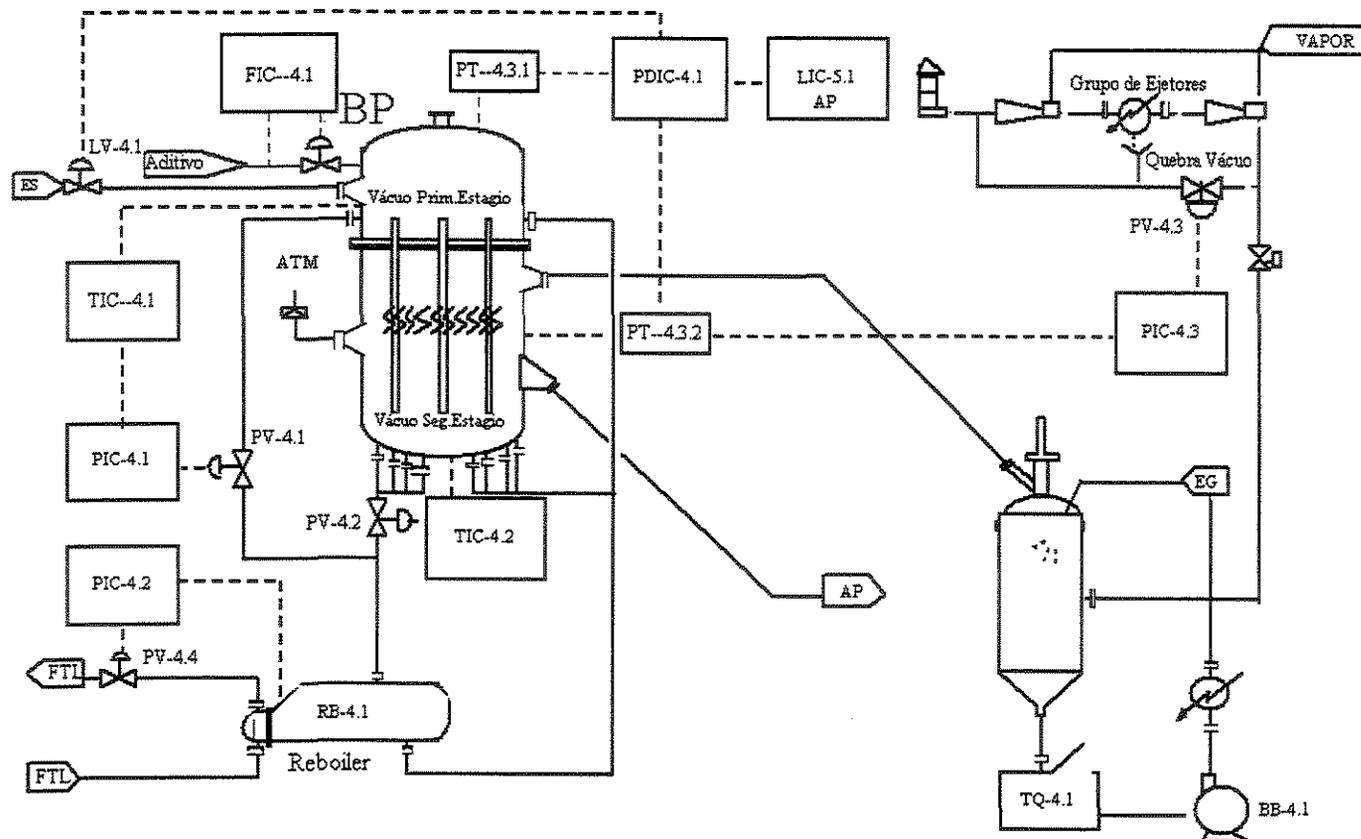


Figura 3.6 - Fluxograma Baixa Polimerização

Análise da Cor do Polímero

A cor do polímero é importante, entre outras coisas, para verificar o nível de degradação do polímero.

Para medida da cor do polímero, atualmente é utilizado o colorímetro Minolta. A medida da cor é feita por um ponto no espaço, através dos eixos:

- eixo X (Cor a) - varia do verde (negativo) até o vermelho (positivo),
- eixo Y (Cor L) Luminância ou brilho do polímero - varia do preto (negativo) até o branco (positivo)
- eixo Z (Cor b) - varia do azul (negativo) até o amarelo (positivo).

Quanto mais o ponto se desloca nos eixos X e Z no sentido positivo e no eixo Y no

sentido negativo, mais degradado será o polímero. (Isso acontece quando se tem alta RM, altas temperaturas de esterificação e polimerização, alto tempo de residência nos reatores, baixos valores de CEG, altas quantidades de catalisadores).

Quando o ponto se desloca nos eixos, no sentido contrário ao citado anteriormente, o polímero será menos degradado. As causas também são inversas daquelas citadas anteriormente.

Obs: Antigamente a medida era L (Luminância) e A (amarelamento) e era feita no equipamento Eurepho.

Variáveis de controle e sua relação com a qualidade

- Temperatura do baixo polimerizador (BP)

É a energia de ativação da reação e esta relacionada com o deslocamento da reação no sentido da formação dos produtos. O aumento da temperatura influencia da seguinte forma:

Aumenta VI

Aumenta cor L , a e b

Aumenta DEG

Diminui CEG do PET

- Vácuo

Está relacionado com o deslocamento da reação no sentido de formação dos produtos já que os ejetores retiram os subprodutos da reação. O aumento do mesmo influencia da seguinte forma:

Aumenta VI

Diminui cor L , a e b

Diminui DEG

Diminui CEG do PET

- Vazão do processo

Está relacionada com o tempo de residência e o aumento da mesma influencia da seguinte forma:

Diminui VI

Diminui cor a e b

Aumenta cor L

Diminui DEG

Aumenta CEG do PET.

3.2.5 Alta Polimerização

Esta é a etapa final do processo de polimerização líquida. Neste ponto do processo é importante o controle do peso molecular do polímero.

No alto polimerizador a copolimerização continua num ritmo mais acelerado, já que as condições de temperatura e vácuo são mais rigorosas.

A geometria do vaso na posição horizontal e o tipo do agitador, que, além de transportar, expõe a massa polimérica continuamente à ação do vácuo e temperatura, favorecendo a reação. O etileno glicol formado é removido através da ação dos ejetores, mantendo dessa forma o equilíbrio da reação. O subproduto apresenta basicamente a seguinte composição:

83% MEG, 9% sólidos, 7% água e 1% DEG.

O PET obtido no alto polimerizador (AP) apresenta cadeias moleculares da ordem de 15000 a 20000 (viscosidade intrínseca entre 0,600 e 0,640 dl/g), que depende do tipo de resina produzida. A figura 3.7 mostra o esquema da fase de polimerização.

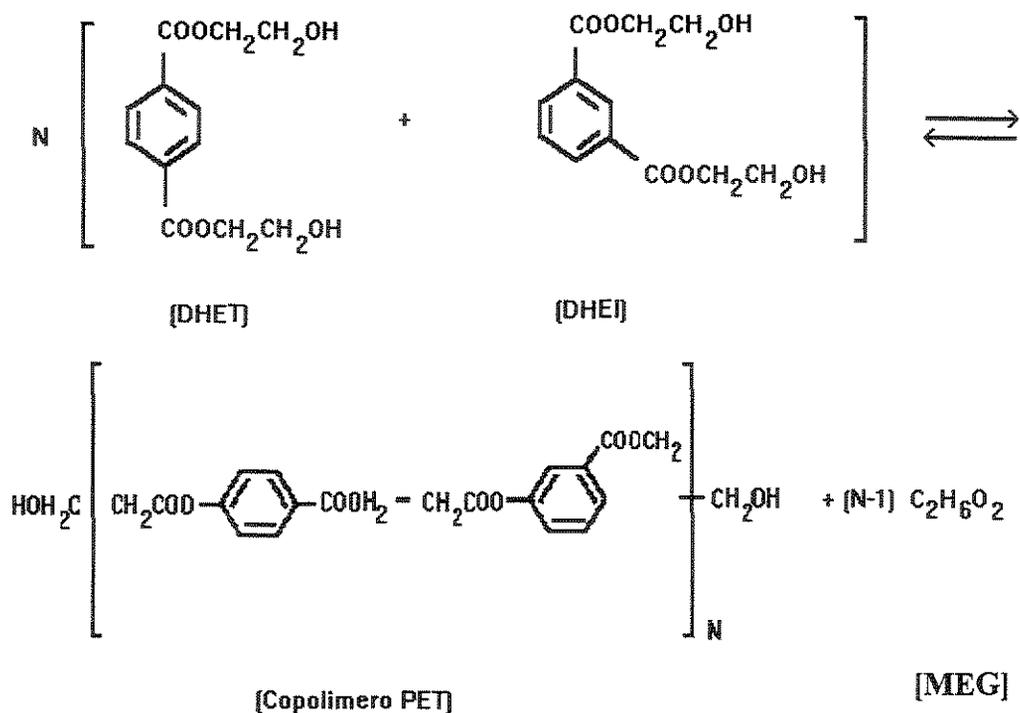


Figura 3.7 Esquema da fase de polimerização

Descrição do processo

O polímero de baixa viscosidade obtido no baixo polimerizador (BP) é transferido ao alto polimerizador (AP) através de um diferencial de pressão entre o baixo e o alto polimerizador. O controle de vazão é o mesmo do BP, isto é, feito através do PDIC-4.1 (diferença de pressão entre o 1º e 2º estágio do BP, que controla a abertura da LV-4.1). O aquecimento do AP é feito através de serpentinas na camisa, com o controle do aquecimento através do TIC-5.1, através do comando da abertura da PV-5.2.

O vácuo do AP é condicionado pelos ejetores através da linha de gases. O controle da pressão é feito através do PIC-5.1, que atua na PV-5.1 (válvula quebra de vácuo do ejetor). O PIC opera em função do sinal do VIC-5.1, onde a viscosidade é especificada.

Tabela 3.5 - Principais variáveis do AP

Nome	Descrição
PDIC-4.1	Controle do nível do BP (atua na válvula de entrada do BP (LV-4.1))
LIC-5.	Controle do nível do AP (altera <i>set-point</i> do PDIC-3.1)
TIC-5.1	Controla a temperatura do AP (faz <i>set-point</i> no PIC-5.2)
PIC-5.1	Controla o vácuo do AP (atua na válvula PV-5.1)
PIC-5.2	Controla a pressão do <i>reboiler</i> (atua na válvula PV-5.2)
LIC-5.2	Controla o nível do tanque receptor do AP (atua na válvula LV-5.2)
BB-5.1	Bomba de polímero
ME-5.1	Motor do agitador do AP
ME-5.2	Motor do raspador
PV-5.1	Válvula quebra vácuo
PV-5.2	Válvula de controle de pressão de fluido térmico <i>reboiler</i>
VIC-5.1	Controla a viscosidade pelo viscosímetro (faz <i>set-point</i> no PIC-5.1)
VIC-5.2	Controla a viscosidade pela corrente do agitador (faz <i>set-point</i> no PIC-5.1)
TQ-5.1	Tanque receptor de glicol
FTL	Fluido térmico no estado líquido

Variáveis de controle e sua relação com a qualidade

- Temperatura do AP

Está relacionada com o deslocamento da reação no sentido de formação dos produtos.

O aumento da temperatura influencia da seguinte forma:

- Aumenta VI
- Aumenta cor L , a e b
- Aumenta DEG
- Diminui CEG do PET

- Vácuo

Está relacionado com o deslocamento da reação no sentido de formação dos produtos, já que os ejetores retiram os subprodutos da reação. Seu aumento influencia da seguinte forma:

Aumenta VI
Diminui cor L, a e b
Diminui DEG
Diminui CEG do PET

Nível do AP

Está relacionado com o tempo de residência; o seu aumento influencia da seguinte forma:

Aumenta VI
Aumenta cor L, a e b
Aumenta DEG
Diminui CEG do PET
Aumenta pontos pretos.

- Vazão do processo

Está relacionada com o tempo de residência; o seu aumento influencia da seguinte forma:

Diminui VI
Diminui cor a e b
Aumenta cor L
Aumenta DEG
Aumenta CEG do PET

A tabela 3.6 mostra qualitativamente a influência de variáveis do processo sobre algumas variáveis da resina:

Tabela 3.6 – Influência da variação das variáveis de processo na qualidade da resina

Aumento na Variável de operação	VI	Cor a e b	Cor L	CEG	DEG	Pontos pretos
Temperatura	↑	↑	↑	↓	↑	↑
Vácuo	↑	↓	↓	↓	↓	-
Nível	↑	↑	↑	↓	↑	↑
Vazão	↓	↓	↑	↑	↑	↓

Sistema de Medição e Controle da Viscosidade

- Viscosímetro

A VI (Viscosidade Intrínseca) é uma medida relativa da média do peso molecular das cadeias poliméricas (ou comprimento das cadeias). O ideal seria medir o comprimento de cadeia, mas essa análise é cara e requer equipamento sofisticado para isso.

Para o polímero PET, opera-se com VI no intervalo entre 0.600 e 0.640 (polímero amorfo) e entre 0.74 e 0.84 (Pós-condensado).

A viscosidade tem papel importantíssimo no processamento do PET, pois através dela pode-se obter informações sobre a conformação das garrafas e outros produtos e dados referentes as melhores condições de processo a serem utilizadas (como temperatura e pressão de injeção e sopro) temperatura de resfriamento do molde, etc.

Viscosidade muito baixa: não se consegue moldar a garrafa (polímero escoo facilmente)

Viscosidade muito alta: necessidade da utilização de altas temperaturas e altas pressões de injeção e sopro, ciclos de resfriamento longos, baixa produtividade, (garrafas com baixa resistência ao impacto e com defeitos de transparência)

A VI também é uma medida relativa da viscosidade do fundido (ou fluidez) do polímero. Essa medida é feita diretamente no processo e sua unidade é em poise. Nesse caso, a medida é feita através de viscosímetro capilar.

A medição da viscosidade do polímero fundido é feita por um viscosímetro em linha, através de um diferencial de pressão, quando o polímero é bombeado através de um tubo capilar.

O viscosímetro está localizado na linha de transferência próximo à boquilha de extrusão. O sinal de medida (em unidade Poise) é enviado ao VIC-5.1, que condiciona o valor desejado no PIC-5.1. O controlador (VIC-5.1) manipula a válvula de quebra de vácuo (para regular o vácuo dentro do AP). O controle da viscosidade no final da linha garante que o produto seja produzido dentro da especificação requerida.

- Amperagem do agitador

O sistema utiliza-se da amperagem do motor do agitador do alto polimerizador (AP) como medida relativa da viscosidade do polímero. Também nesse sistema, quando a viscosidade da massa aumenta, maior será a potência necessária para movimentação do agitador e, conseqüentemente, maior será a amperagem. Como a variação de nível ou problemas mecânicos, podem interferir na amperagem, o controle da viscosidade pela corrente é somente utilizado quando o viscosímetro não está operando corretamente.

- Bloco viscosímetro

Características:

O conjunto opera com os seguintes equipamentos:

- Termo-bulbo
- Capilar
- Bloco da bomba
- Sensor de pressão
- Painel de Controle
- Motor

- Aquecedor
- Bomba dosadora
- Bomba de descarga
- Válvula especial

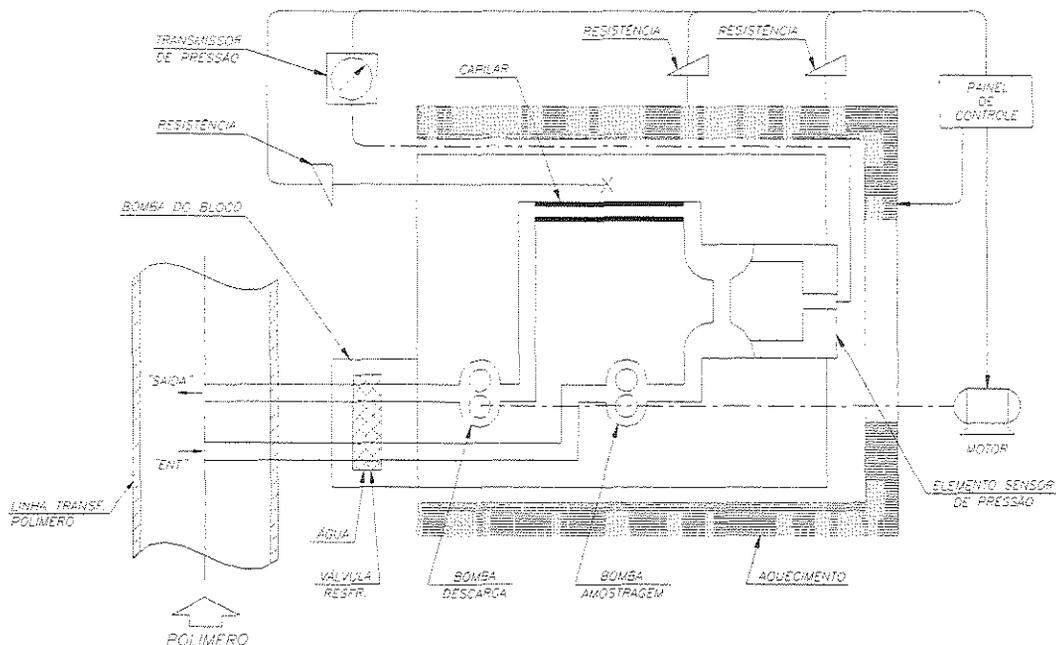


Figura -3.9 Bloco Viscosímetro

- Características do Bloco Viscosímetro

Princípio de operação: O polímero fundido da linha principal entra pelo tubo de entrada, passa pela válvula especial (resfriamento), bomba de amostragem, medidor de pressão, tubo capilar, bomba de descarga, válvula especial e finalmente é devolvido pelo tubo de saída à linha principal. Como o tubo capilar e o polímero fundido atendem as condições previstas na lei de Hagen-Poiseuille, existe uma relação proporcional entre pressão diferencial através do tubo capilar e a viscosidade do polímero fundido. A viscosidade do polímero é conhecida pela medição da pressão diferencial.

Condições descritas para aplicação de Hagen-Poiseuille:

- (1) O fluido passa pelo tubo capilar em camadas paralelas (fluxo laminar) sem alteração do tempo de passagem (fluxo constante).
- (2) Tubo capilar com comprimento suficiente e com diâmetro interno igual ao comprimento total do tubo.

- (3) Líquido não compressível
- (4) O líquido não adere a parede interna do tubo capilar
- (5) O fluido é do tipo Newtoniano (para se medir a viscosidade de um fluido não Newtoniano, como o PET, que é Pseudoplástico, é necessário a correta seleção dos seguintes fatores: apropriadas taxa de cisalhamento e vazão, associados ao diâmetro e comprimento do tubo capilar)

$$v = \frac{\pi \cdot r^2 \cdot (P_1 - P_2)}{8 \cdot L \cdot Q} \quad (3.2)$$

Onde:

V= Viscosidade (Poise)

r = raio interno do tubo capilar (cm)

L = Comprimento do tubo capilar (cm)

Q = Volume de fluxo através do tubo capilar

P₁ = Pressão na entrada (dyn / cm²)

P₂ = Pressão na saída (dyn / cm²)

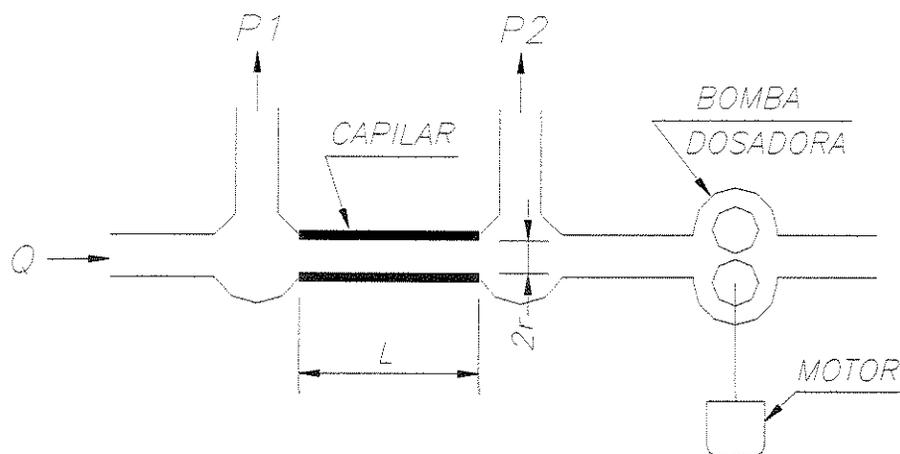


Figura 3.10 Esquema do princípio de medida da viscosidade

As principais intervenções nos viscosímetros são: limpeza do capilar, troca de bombas, aferição do transmissor de pressão e acerto das escalas de conversão.

3.2.6- Extrusão e Corte

O polímero pronto é extrudado em uma placa perfurada de modo a se obter os espaguetes que são resfriados e cortados na forma de pequenos grãos chamados chips. Estes grãos serão a matéria prima para a próxima etapa do processo que é a polimerização no estado sólido (SSP), que não faz parte do estudo deste trabalho.

3.3 Variáveis para Treinamento da Rede Neural

O uso de redes neurais artificiais para criação do Soft-Sensor deve-se principalmente à sua capacidade de representação de comportamentos não lineares arbitrários, que são bem adequados as aplicações desta dissertação.

Dessa forma, foram escolhidas as principais variáveis do processo de significativa sensibilidade sobre a viscosidade e confiabilidade no monitoramento. Estas escolhas foram baseadas na experiência de anos de trabalho dos engenheiros e operadores do processo, bem como nos resultados do simulador de processo desenvolvido na empresa.

A figuras 3.11 e 3.12 ilustram os resultados da sensibilidade da viscosidade. A tabela 3.7 apresenta as variáveis consideradas para o treinamento da rede neural de representação da viscosidade.

Tabela 3.7 - Variáveis para treinamento da Rede Neural

	Variáveis de Entrada	Nome
1	Temperatura do EP	TT-2.1 (TIC-2.1)
2	Temperatura do ES	TT-3.1 (TIC-3.1)
3	Temperatura do segundo estágio do BP	TT-4.2 (TIC-4.2)
4	Temperatura do AP	TT-5.1 (TIC-5.1)
5	Vácuo no segundo estágio do BP	PT-4.3.2 (PIC-4.3)
6	Vácuo no AP	PT-5.1 (PIC-5.1)
7	Vazão do aditivo, que tem a função de catalisador.	FT-4.1 (FIC-4.1)
	Variável de Saída	
1	Viscosidade medida pelo viscosímetro	VT-5.1 (VIC-5.1)

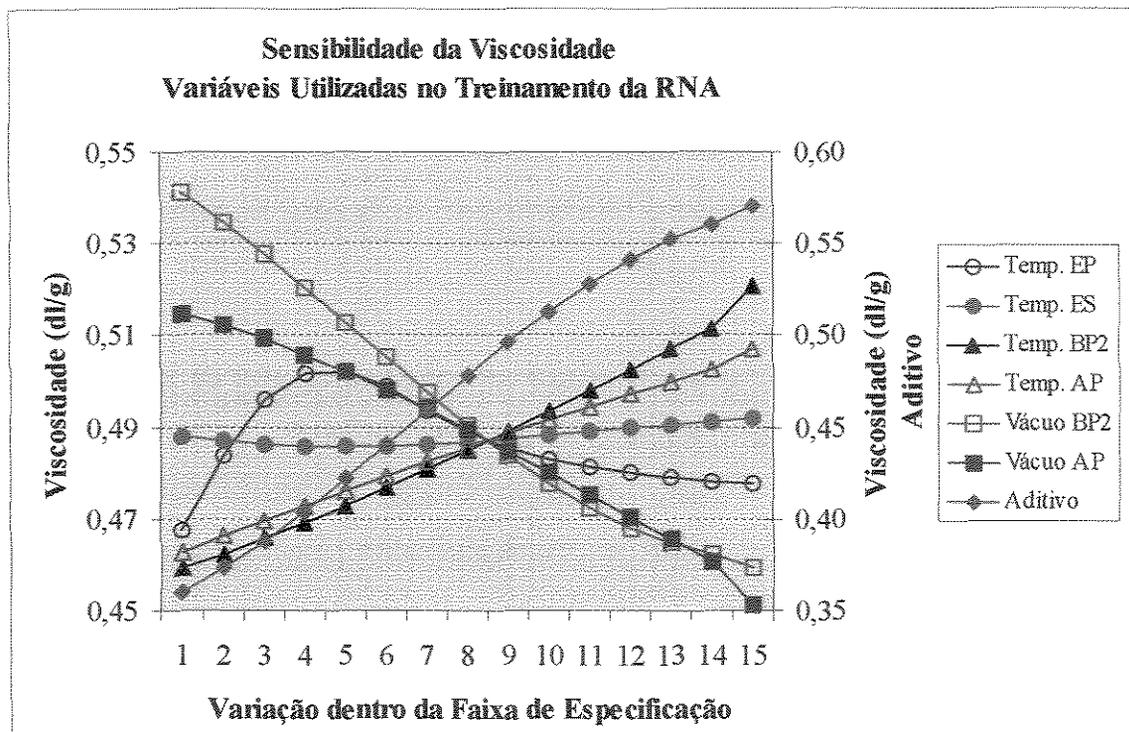


Figura 3.11 - Sensibilidade da viscosidade obtida através de um simulador de processo desenvolvido na empresa.

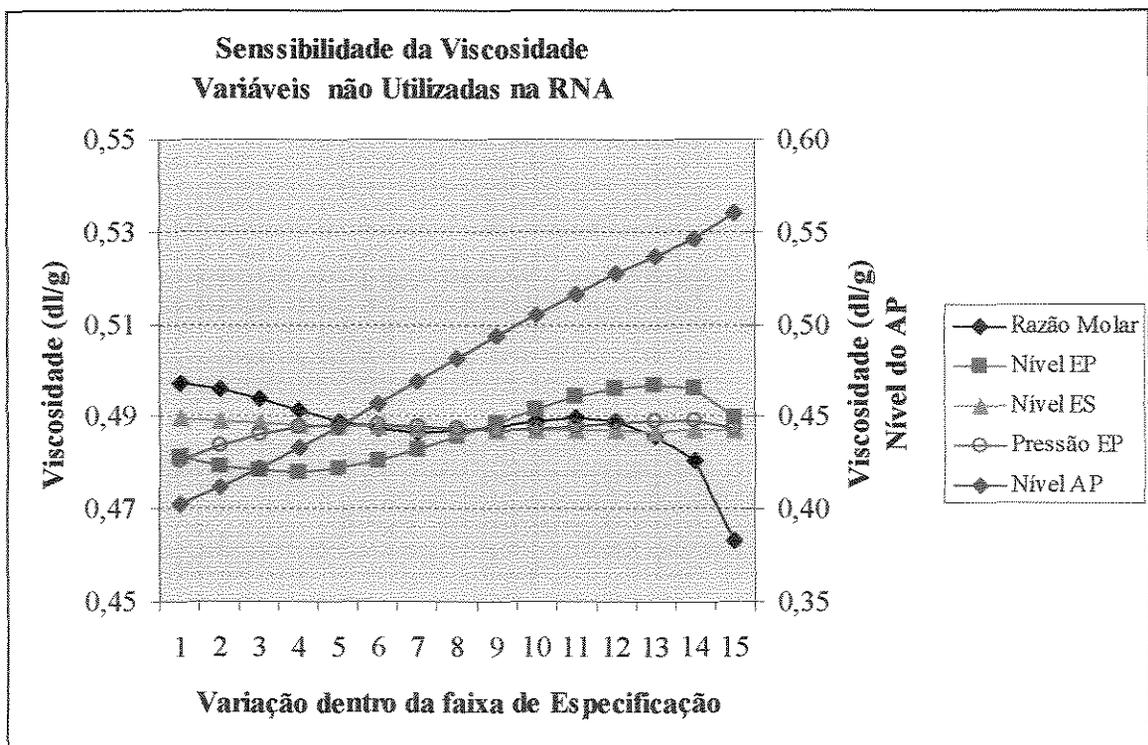
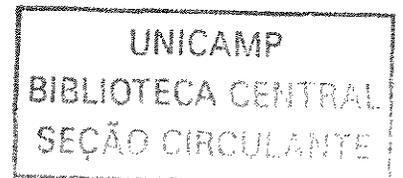


Figura 3.12 - Sensibilidade da viscosidade obtida através de um simulador de processo desenvolvido na empresa.



3.4 Conclusões

Este capítulo tem como objetivo promover um conhecimento sobre a planta de produção de Poliester, mostrando as principais variáveis de controle, principalmente aquelas relacionadas à viscosidade e, dessa forma, justificar a escolha das mesmas.

Cabe ressaltar que, se não houvesse um considerável nível de ruído presente nas medições, a razão molar (RM) e o nível do AP poderiam também ser utilizadas no sistema de treinamento da rede. Assim, em etapas futuras, a inclusão dessas variáveis no desenvolvimento da rede neural parece ser uma alternativa bastante propícia de modelagem de processos.

As variáveis de processo apresentadas neste capítulo são todas controladas pelo CLP (capítulo 4), que usa algoritmos de controle padrão ISA (parâmetros PID dependentes) ou padrão Alenn-Bradley (parâmetros PID independentes). A tabela A.1 (Apêndice A) mostra as diferenças entre as duas equações. Todas as malhas estão sintonizadas usando o padrão ISA, permitindo um bom desempenho de controle de processo.

CAPÍTULO 4

ARQUITETURA DO SISTEMA DIGITAL DE CONTROLE

4.1- Introdução

O processo de produção de PET, como já foi descrito no capítulo anterior, envolve uma quantidade significativa de equipamentos e variáveis de processo. Dessa forma, um Sistema Digital de Controle (SDC) foi desenvolvido para permitir uma supervisão de todos os eventos da planta e disposição de algoritmos de controle automático para controlar as principais variáveis de processo. Neste capítulo, o SDC adotado (da planta da Rhodia-Ster de Poços de Caldas.) é apresentado. O objetivo deste capítulo é propiciar uma visão geral da topologia de rede do sistema de supervisão e controle, descrevendo de forma sucinta cada parte do sistema e, por fim, mostrar o monitoramento da viscosidade no sistema.

4.2- Sistema Digital de Controle Distribuído (SDCD)

O sistema de controle empregado é distribuído para permitir uma independência de funcionamento das linhas, propiciando maior flexibilidade para programação de paradas de manutenção, que sempre são necessárias. A escolha por esse sistema distribuído se deve a divisão da planta em várias linhas de produção e estas estarem divididas em sistemas de fabricação (utilidades, transferência de produtos e etapas de polimerização). Devido à experiência de funcionários da manutenção com Controladores Lógicos Programáveis (CLP's) (produzidos pela Allen Bradley) e à facilidade de interconecção dos mesmos para formar uma estrutura distribuída, o sistema é constituído por uma rede de CLPs e outra rede de Interface Homem Máquina (IHM); sendo que esta é centralizada em um servidor de rede, onde se localiza a base de dados. A integração dessas duas redes (CLPs e IHM) forma uma única rede local (rede industrial) ou LAN (*Local Area Network*), constituindo assim um Sistema Digital de Controle Distribuído (SDCD).

4.3- Controlador Lógico Programável

O CLP ou PLC (*Programmable Logic Controller*) trata-se de um *hardware* para controle de máquinas e processos, que utiliza uma memória programável para armazenar instruções e executar funções específicas (controle de energização/desenergização, temporização, contagem, seqüenciamento, operações matemáticas e manipulação de dados).

A unidade central de processamento (CPU – *central processing unit*) e a interface de entradas e saídas do sistema são consideradas as seções básicas de um CLP. A CPU realiza todo o processamento computacional do CLP, sendo formada pelo processador e sistema de memória. O sistema de entradas e saídas é conectado fisicamente nos dispositivos de campo (interruptores, sensores, etc.) e possibilitam também uma interface entre a CPU e o meio externo – IHM.

Operacionalmente, a CPU executa a função de leitura dos dados de entrada dos dispositivos de campo através da interface de entrada e, então, realiza os controles de programa armazenados na memória. Os programas são normalmente realizados na linguagem Ladder (figura 4.1) e são armazenados na memória da CPU em forma de operações. Finalmente, de acordo com o programa, o CLP escreve ou atualiza as saídas, atuando nos dispositivos de campo. O nome Ladder se deve a forma da apresentação gráfica, semelhante a uma escada. Esta linguagem de programação teve uma boa aceitação entre os técnicos e engenheiros que estavam acostumados a trabalhar com sistemas de controles a relés, visto que se assemelha a esquemas elétricos baseados em relés.

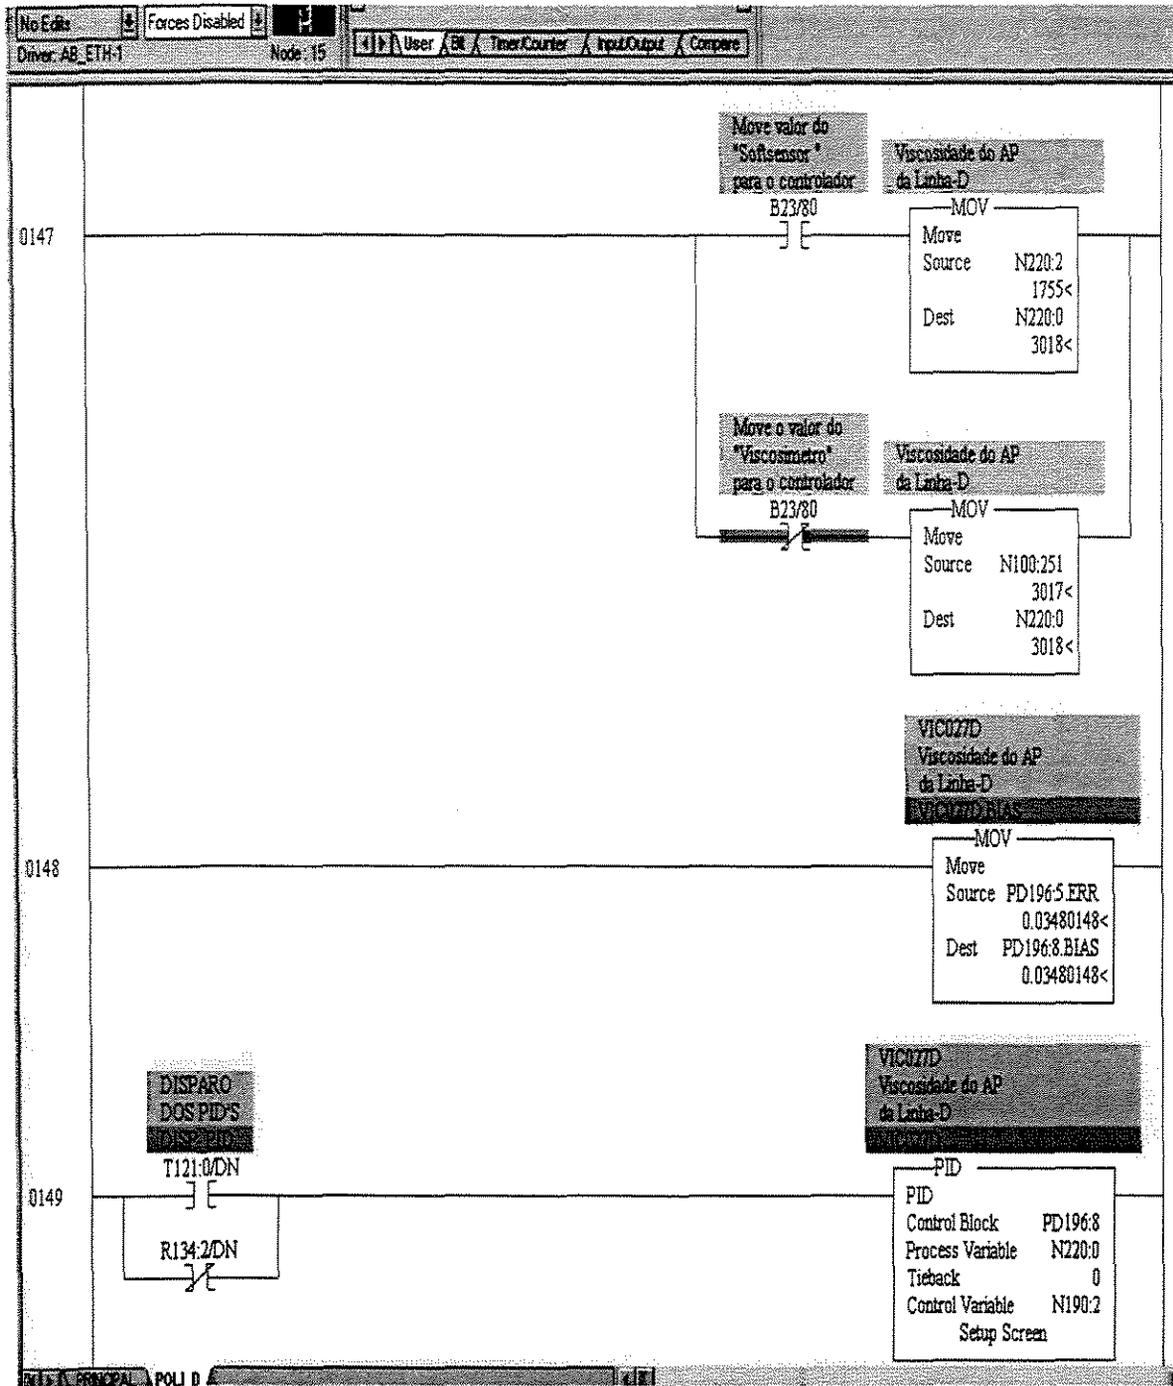


Figura 4.1- Linguagem de programação Ladder

4.3.1- Pontos de Saída

Cada sinal enviado pelo CLP para comandar dispositivos ou atuadores, como bobinas de relés, válvulas solenóides, lâmpadas, etc., são considerados pontos de saída. As saídas podem ser digitais ou analógicas.

As saídas digitais fornecem apenas dois estados: ligado ou desligado. As saídas analógicas permitem variar o nível de saída em uma faixa. São utilizadas para controlar válvulas e outros dispositivos. Exemplo: a saída varia de 4 a 20 mA e a abertura da válvula varia de forma proporcional de 0 a 100%.

4.3.1.1- Especificação de Módulos de Entrada e Saída

Normalmente, as características necessárias de entrada e saída requisitadas para seleção de um CLP são:

- Número de I/O;
- Níveis dos sinais de entrada/saída;
- Tempo aceitável para varredura;
- Índice de proteção;
- Isolação elétrica entre entradas;
- Tipo de sinal de entrada;
- Corrente de saída;
- Freqüência de acionamento das saídas.

Além da comunicação com outros sistemas de controles, o CLP pode também realizar funções que indiquem suas próprias falhas, bem como as falhas de máquina ou processo.

A rede de CLPs é formada por diversos modelos conforme a necessidade de cada área, sendo que as áreas principais possuem redundância de CPU (*Hot Backup*).

A escolha de um CLP está ligada diretamente ao tamanho do projeto e nível de confiabilidade desejada. Geralmente um CLP é identificado pelo tamanho (por exemplo:

um *CLP 5/40E* é um CLP da família 5 com 50 k de memória e com porta de comunicação ethernet, já o *CLP 5/80E* é um CLP com 100 k de memória)

4.3.1.2- Aspectos relevantes na escolha de um CLP

- Número de I/Os;
- Utilização Remota/Local;
- Necessidade de PID;
- Memória (dados e programa);
- Velocidade;
- Comunicação (rs232, ethernet, rs485, fieldbus, fibra ótica, etc);
- Outras interfaces;

A figura 4.2 mostra o diagrama de blocos de um CLP, as figuras 4.3, 4.4, 4.5 e 4.6, mostram fotos de várias partes do CLP, representadas no diagrama de blocos.

A figura 4.7 mostra o diagrama de blocos da malha de controle da viscosidade.

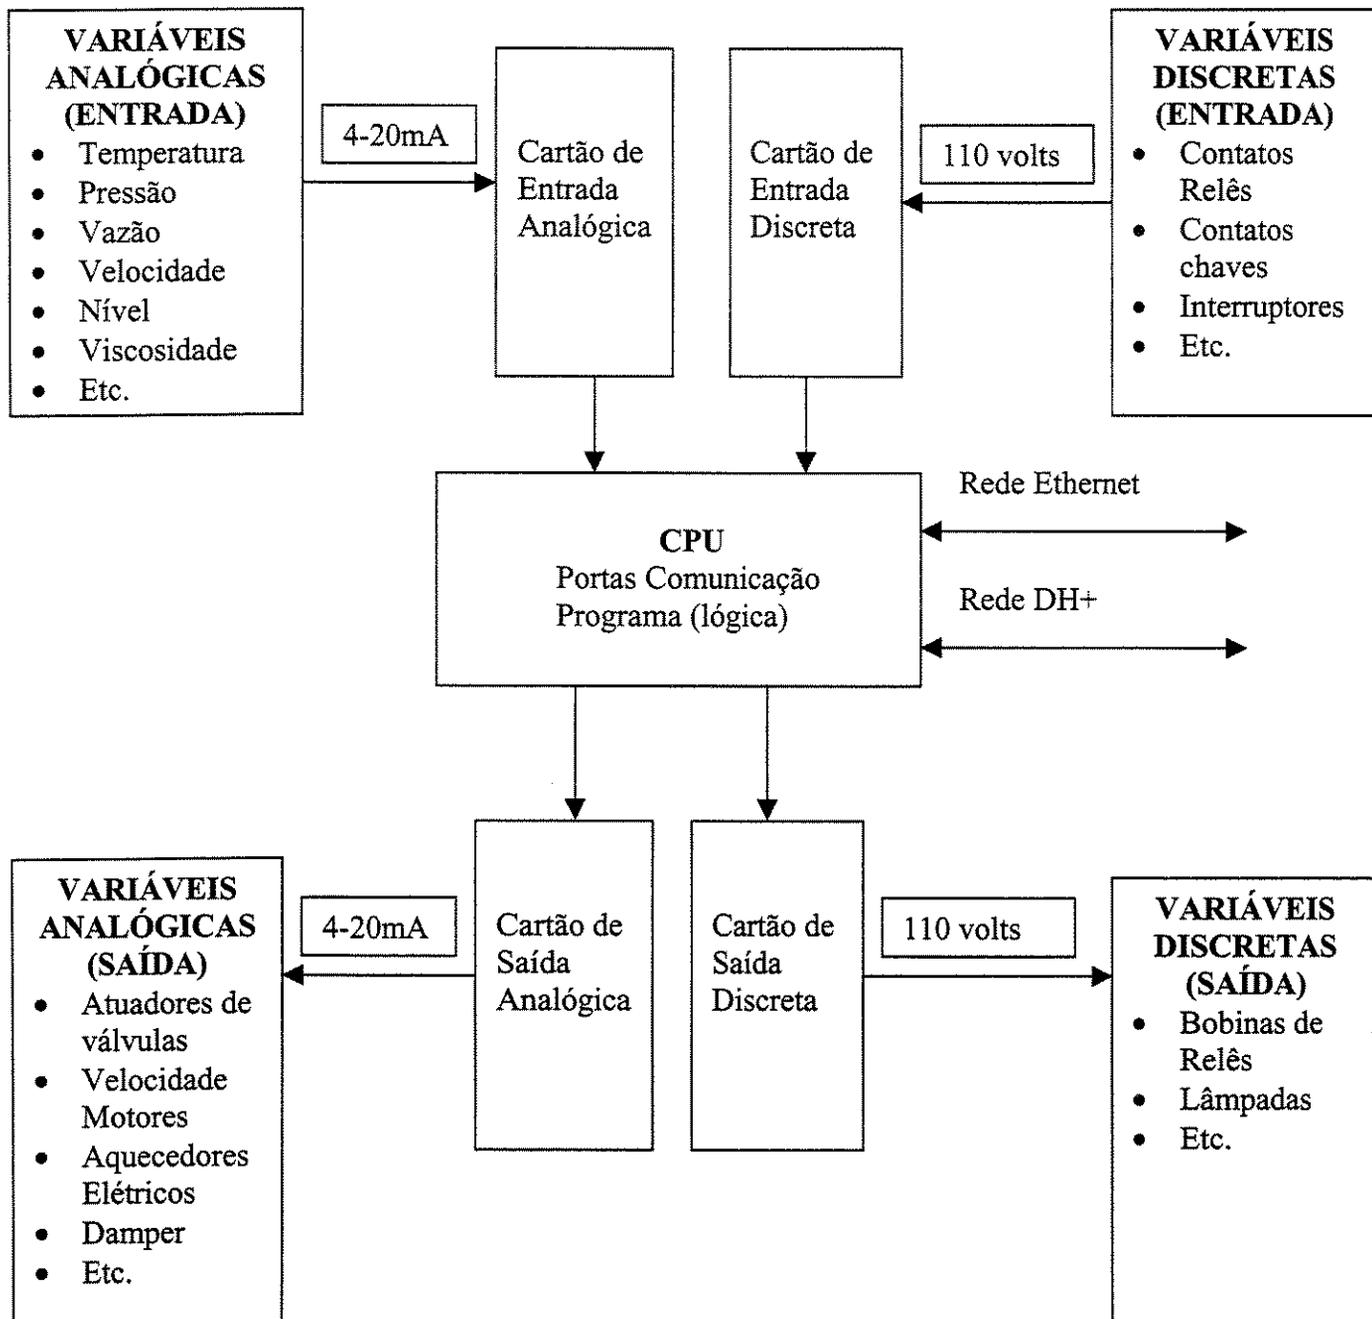


Figura 4.2 - Diagrama de Blocos de um CLP

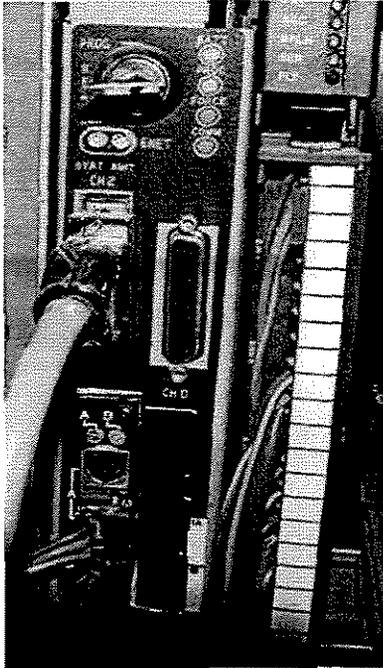


Figura 4.3
CPU de um CLP da
Allen Bradley

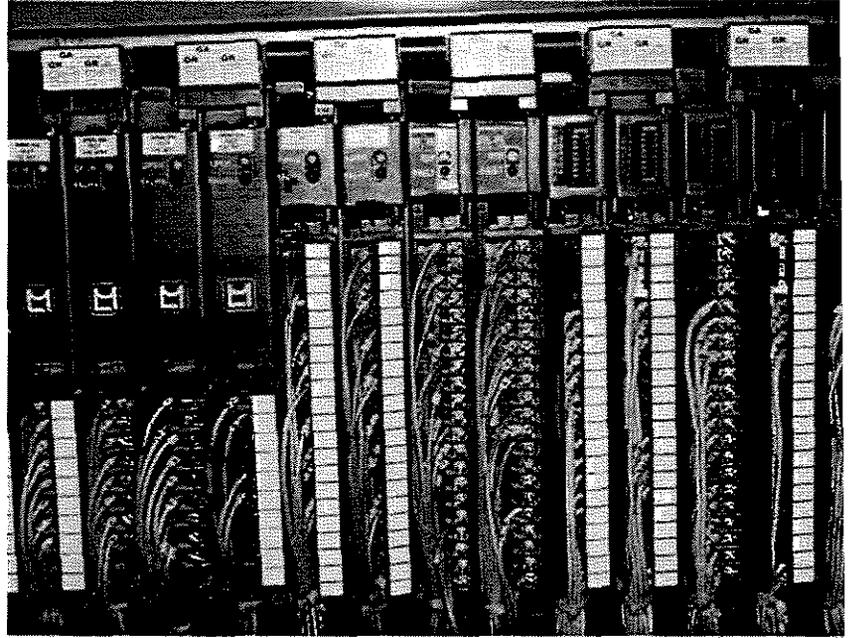


Figura 4.4
Interface de entrada e saída (Cartões do CLP).

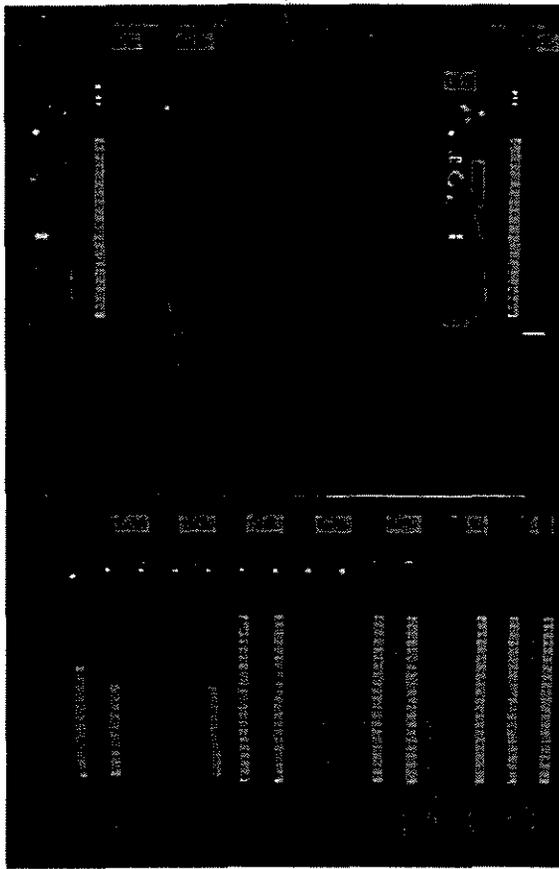


Figura 4.5 Coluna de um painel do CLP



Figura 4.6 Painel do CLP de uma Linha de Produção

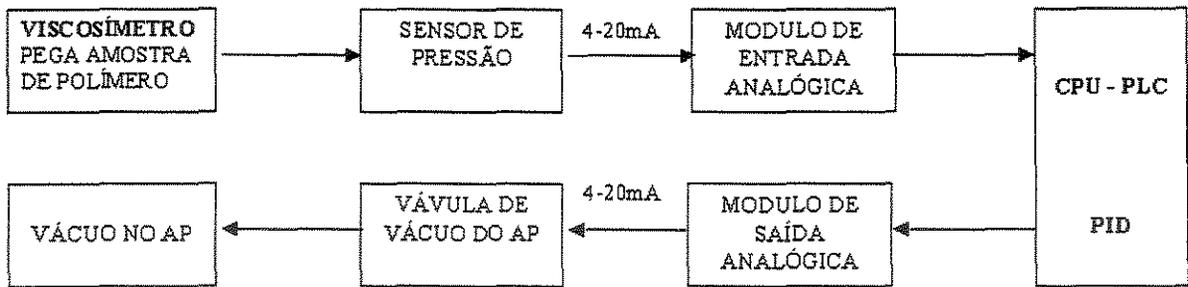


Figura 4.7 - Diagrama de Blocos da Malha de Controle da Viscosidade

4.4- (IHM) - Sistema de Supervisão

Como descrito nos itens anteriores, os CLP's tem como função principal controlar a planta através da interface entre as entradas e as saídas do campo. A interface com o operador de produção ou engenheiro de processo é feita através de um sistema de supervisão, que pode ser do próprio fabricante do CLP ou de uma outra empresa que possua o *driver* de comunicação. Na Rhodia-Ster foi escolhido o sistema da Aspentech, usando os *softwares* Setcim para a base de dados e o GCS como configurador gráfico.

O sistema IHM é composto por dois servidores redundantes, AlphaServer 1000, onde está instalado o Setcim e, seis consoles de operação Alpha Station 200, onde está instalado o GCS (*Graphic Console System*), que é a IHM. Todo o sistema de supervisão roda sobre uma plataforma Alpha, usando o sistema operacional OpenVms.

4.4.1- Setcim

O Setcim é um software de alto desempenho em que um banco de dados é atualizado em tempo real, com memória residente que caracteriza um armazenamento dinâmico e customizada. O mesmo também se caracteriza como um componente de disco residente que fornece um armazenamento ilimitado para fluxos de dados históricos.

Todos os dados no Setcim são organizados em unidades fundamentais chamadas de *Record*. Aplicações podem ler ou escrever dados que usam (entre outras opções) uma rica Interface de Programação de Aplicações (API- *Application Programming Interfaces*), suportado por Serviços de Chamadas Remotas a Procedimentos (RPC- *Remote Procedure Call*). Uma descrição mais detalhada sobre API e RPC é encontrada em Teixeira Júnior et al. (1999).

4.4.2- Tarefa Externa (*External Task*)

Uma das principais opções oferecidas pelo Setcim é a possibilidade de desenvolvimento de complexas aplicações (*External Task*) em linguagens de programação como Fortran e C e associá-las ao banco de dados.

Uma aplicação customizada (ou "tarefa" externa) é um processo destacado que responde à atividade de banco de dados e executa manipulação de dados. Para que essas aplicações possam ser utilizadas, as mesmas precisam ser inicializadas. Uma tarefa externa pode ser ativada de diversas maneiras: inclusão no programa de campos de ativações de mudança de estado (na inicialização do Setcim ou manualmente através de um arquivo de comando). O Telecomando executado pelo operador para ligar/desligar um equipamento através da IHM é um exemplo de uma Tarefa Externa, que foi construída de acordo com o sistema em operação. Esta tarefa é ativada quando o Setcim é iniciado. Não existe limite para construção de tarefas externas. Na realidade, uma Tarefa Externa é um processo que roda independente e que está ligado apenas aos registros que foram criados para chamá-lo. A figura 4.8 mostra o esquema da conexão de uma tarefa externa com o Setcim e a figura 4.9 mostra uma aplicação de uma tarefa externa construída para fazer a interface de entrada/saída de dados do Setcim com o CLP.

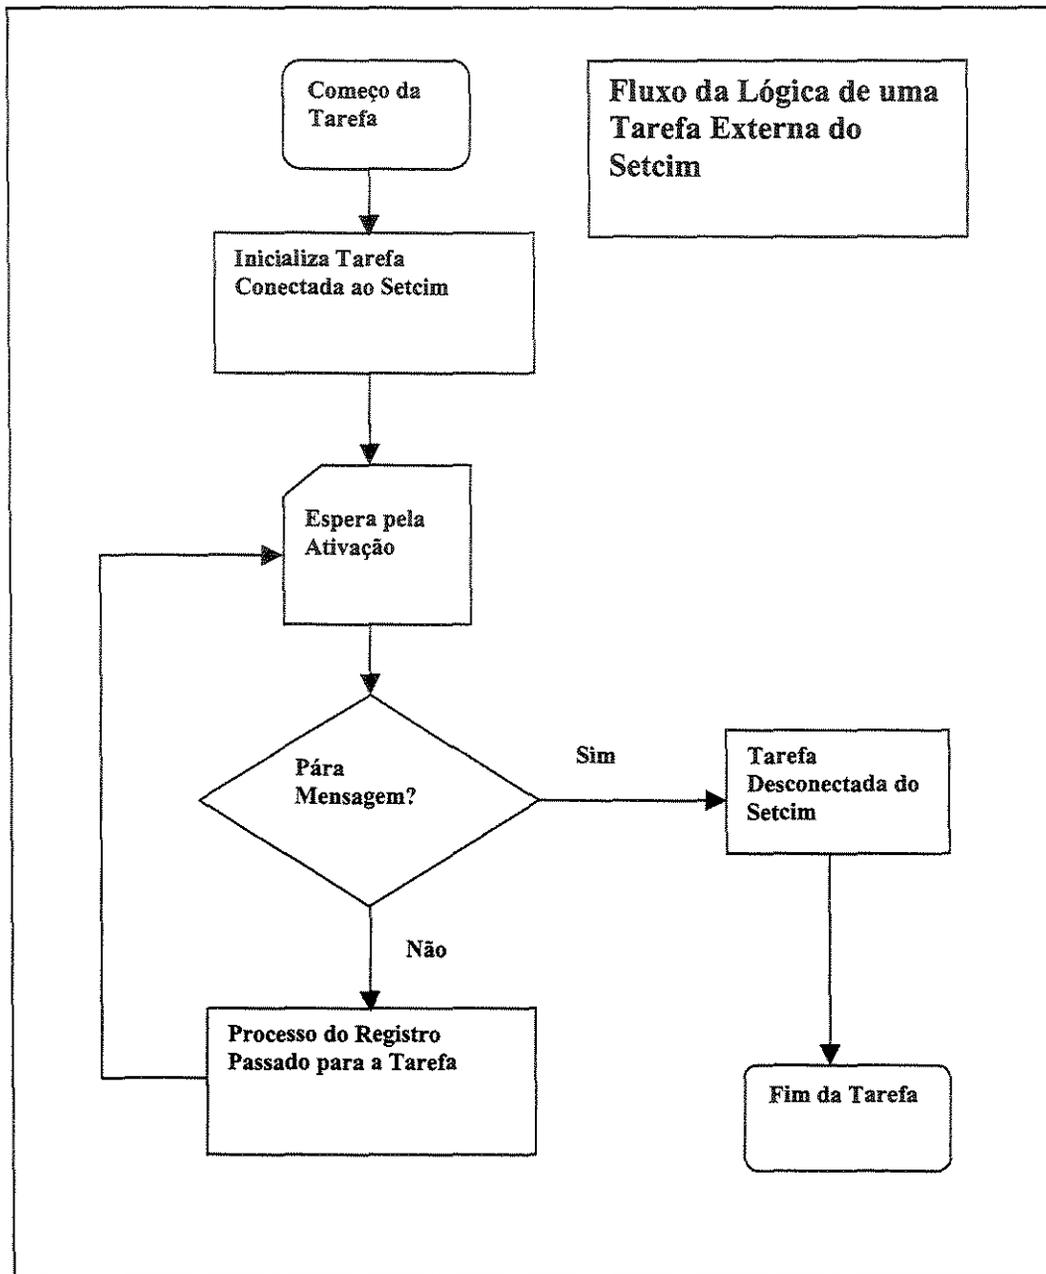


Figura 4.8 - Fluxo da Lógica de uma Tarefa Externa do Setcim

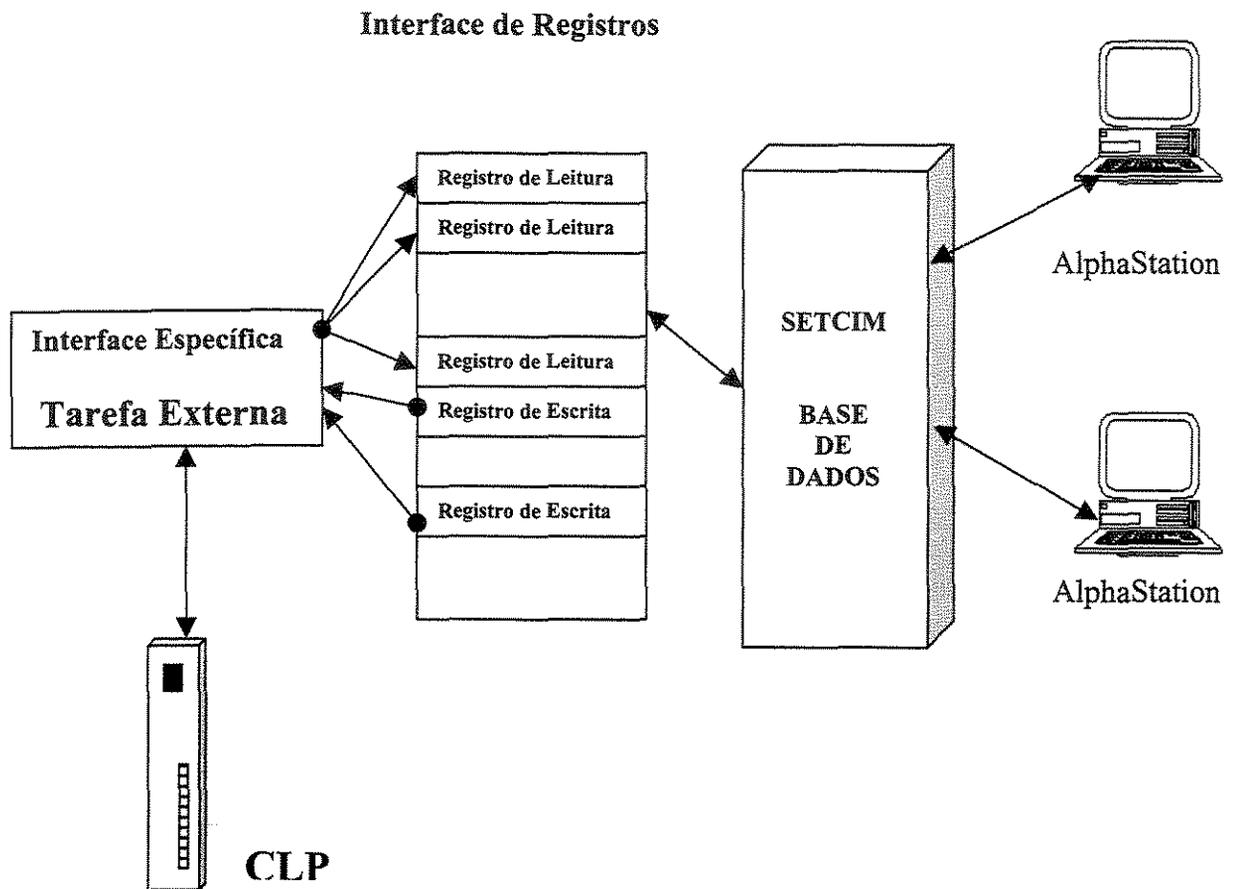


Figura 4.9 - Relação de uma Definição de Registro e uma Tarefa Externa

4.5- Topologia de Rede do Sistema de Supervisão e Controle

Conforme descrito nos itens anteriores, os equipamentos do SDCD da Rhodia-Ster estão todos ligados em uma LAN (industrial), usando um protocolo de comunicação TCP/IP. Para otimizar o tempo de resposta, cada CLP possui duas portas de comunicação:

i) Data Highway Plus (DH+) - que é um protocolo proprietário da Allen-Bradley, para comunicação entre os CLP's; e ii) Ethernet - para comunicação com as IHM.

Além do Setcim e do GCS, outros *softwares* estão instalados nos PCs da rede corporativa (uma outra LAN), que está interligada com a rede industrial através de um computador, que possui duas placas de comunicação, uma para cada rede, atuando assim, como uma ponte. Estes *softwares* são utilizados para acompanhamento do processo, levantamento estatístico e edição dos programas de CLP. Os principais são:

Process Explorer (Aspentech) - utilizado para criar gráficos e análise estatística em tempo real. Disponibiliza ainda, a base de dados em tempo real, para ser usada no Excel e construir relatórios customizados, usando todos os recursos da planilha eletrônica.

RSTune (Rockwell Software) - utilizado para auxiliar na sintonia das malhas de controle. Possibilita sintonizar uma malha de controle, usando tanto o método de malha aberta como o de malha fechada, gerando um relatório completo com gráficos ilustrativos para análise do comportamento do controle após a aplicação dos valores dos parâmetros relativos aos "PID's" propostos para a sintonia.

RSLogix (Rockwell Software) - utilizado para programação de CLP.

RSGuardian (Rockwell Software) - utilizado para *backup* e geração de relatórios comparativos de arquivos, informando momento e local de alteração do programa. Este programa fica residente na memória do computador e é executado sistematicamente em função de um período pré-estabelecido.

Todos os softwares citados acima executam-se em PC's, usando o sistema operacional Windows, inclusive o GCS, que além de se executar no sistema OpenVms,

executa-se também no sistema windows em uma outra versão apropriada. A figura 4.10 mostra uma parte da topologia de rede da Rhodia-Ster.

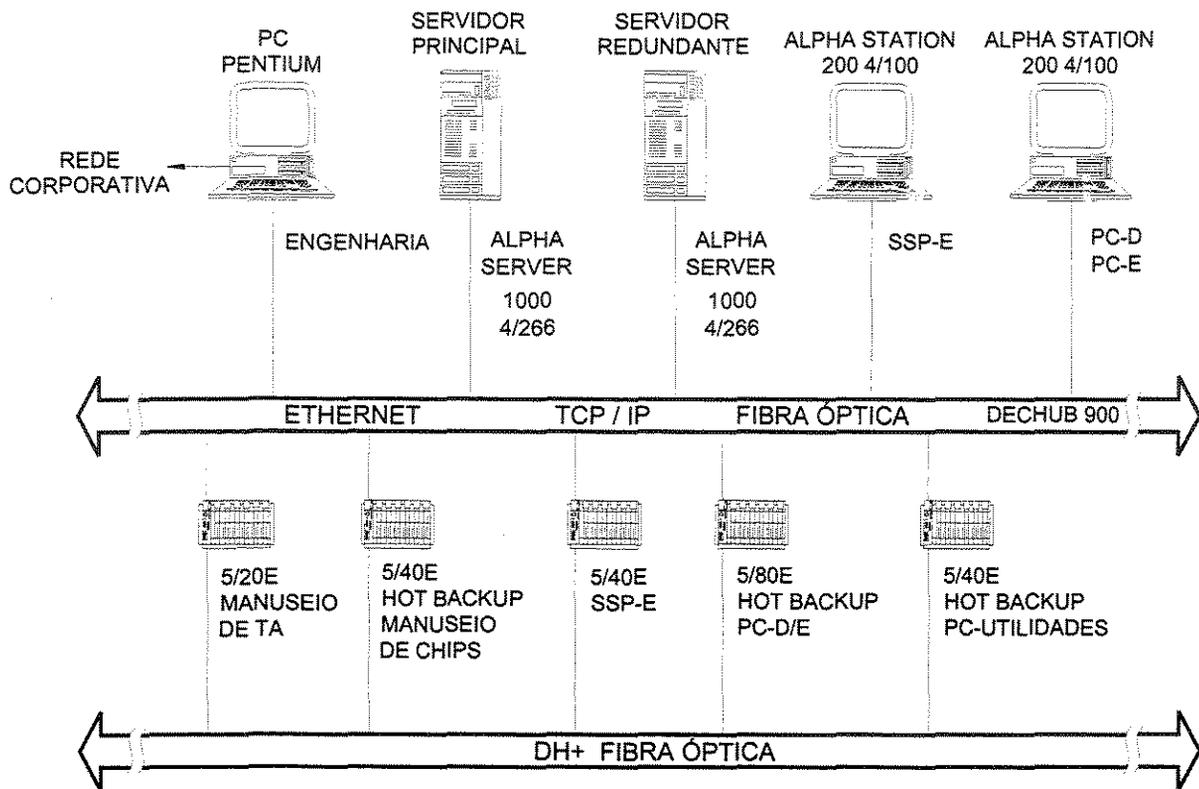


Figura 4.10 - Topologia de Rede

4.6 - Conclusões

O SDCD da Rhodia-Ster pode ser considerado como um sistema robusto, onde as indicações e controles das variáveis de processo apresentam um comportamento confiável, garantindo uma cadência de produção tranqüila e perene. Obviamente, como todo sistema de controle industrial, não está imune a falhas derivadas de equipamentos ou dispositivos, que causam danos ao controle do sistema e, possivelmente, à produção. Isso tem sido objeto de estudo em diversas plantas industriais e, por conseguinte, muitas empresas têm investido em técnicas alternativas para prever uma possível falha ou até mesmo substituir estas indicações durante o período de falha. Como pôde ser visto neste capítulo (Figura 4.7), a medição da viscosidade depende de uma seqüência de etapas para alcançar o monitor de operação. E, conforme descrito acima, tudo isso pode contribuir para uma falha na medição da viscosidade (falha no viscosímetro, no sensor de pressão, no cartão de entrada e até mesmo no cabeamento, etc.). Neste capítulo, foram abordados assuntos relativos à implementação de processos executados de forma independente e interconectados no Setcim. No capítulo seguinte, apresenta-se a interconexão dessas informações ao Setcim para criação de uma nova tarefa, o Soft-Sensor, que é o objeto de estudo desta pesquisa.

CAPÍTULO 5

DESENVOLVIMENTO DO SOFT-SENSOR

5.1 - Introdução

Este capítulo descreve os procedimentos necessários para a implementação de um Sensor Virtual (*Soft-Sensor*) utilizado para a predição da viscosidade em reatores de polimerização. Os tópicos abordados estão divididos da seguinte forma:

- O que é o modelo, no que se baseia e quais são os algoritmos utilizados.
- Descrição do procedimento e dos critérios.
- Implantação do modelo e acompanhamento.
- Integração com o SETCIM.

5.2 - O Que é o Modelo, no Que Se Baseia e Quais São os Algoritmos Utilizados.

Os desenvolvimentos mais recentes relacionados à identificação de processos estão associados a sistemas com capacidade de reconhecimento de padrões, aprendizado e supervisão de processos (detecção de falhas), assim como o desenvolvimento de “softwares” que sejam capazes de estimar grandezas e estados de um processo que normalmente não estão acessíveis. Dentro dessa tendência, uma das técnicas que vem se destacando é o Sensor Virtual ou *Soft-Sensor* desenvolvido a partir de redes neurais artificiais (RNA).

A literatura tem reportado várias aplicações de sucesso dos *Soft-Sensors* nas mais variadas aplicações da Engenharia Química, pois em face às dificuldades de medida, alto custo envolvido na obtenção de algumas variáveis de processo, ou ainda a deterioração da qualidade dos dados medidos devido a problemas nos sensores, por exemplo, têm-se investido muito no desenvolvimento de *Soft-Sensors*” como alternativa para contornar tais problemas. Neste trabalho propõem-se utilizá-los com um sensor virtual para estimar a

viscosidade em tempo real dos reatores de polimerização, proporcionando uma leitura alternativa e robusta da viscosidade.

5.2.1 *Soft-Sensors*

O conhecimento em tempo real de todos os estados de um sistema é fundamental para o seu completo monitoramento e necessário nas estratégias de controle do processo. Como nem todos esses estados são diretamente mensuráveis ou as medidas em tempo real são disponíveis com atrasos e/ou possuem custo muito elevado, as técnicas de *estimativa de estado* constituem em uma proposta interessante na solução deste problema.

Dentre as várias técnicas disponíveis para realizar as estimativas em tempo real dos estados de um processo, uma das mais interessantes e que vem merecendo destaque na literatura científica (Tham *et al.*, 1989) são as que utilizam um “software” chamado de *Soft-Sensor*. Esse “software” é a implementação computacional de um filtro ou de um observador de estado. No caso específico da *Rhodia-ster*, utilizou-se redes neurais artificiais como um observador de estados não linear.

Para a obtenção de informações sobre os estados do sistema, dadas as restrições e dificuldades no monitoramento de processos químicos, o desenvolvimento de *Soft-Sensors* parece ser a solução adequada (Tham *et al.*, 1989). Os *Soft-Sensors* podem ser utilizados como sensores virtuais de um processo, possibilitando ao engenheiro de processo uma rápida e confiável leitura das variáveis de interesse. Além disso, os *Soft-Sensors* podem ser usados como fontes de dados preditivos para fins de controle, de forma que características preditivas são incorporadas na decisão do controlador. Este tipo de informação sobre o processo tende a melhorar o desempenho do controlador, principalmente quanto à sua habilidade de extrapolação.

Uma vez que a teoria das Redes Neurais Artificiais é a base matemática sobre a qual o *Soft-Sensor* foi desenvolvido, um resumo sobre as mesmas se faz importante e é apresentado na seqüência deste documento.

5.2.2 - Redes Neurais Artificiais

As redes neurais artificiais (RNA) têm se tornado recentemente foco de muita atenção, principalmente devido à sua capacidade de aprendizado, à ampla gama de aplicabilidade e à facilidade com que armazena conhecimento experimental e o torna disponível para o uso em aplicações de Engenharia de Processo. Essas redes são modelos matemáticos inspirados em sistemas biológicos neurais teorizados, que foram desenvolvidos de modo a imitar os mecanismos de entendimento e cognição humanos (Figura 5.1).

Uma RNA é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento “inteligente” de uma RNA vem das interações entre as unidades de processamento da rede.

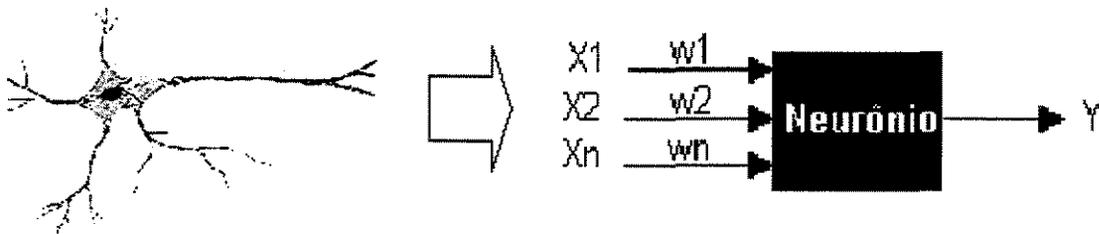


Figura 5.1 – Analogias entre os neurônios biológico e matemático.

A operação de *uma* unidade de processamento, proposta por McCulloch e Pitts em 1943 (Figura 5.2), pode ser resumida da seguinte maneira:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível de atividade exceder um certo limite (*threshold*) a unidade produz uma determinada resposta de saída.

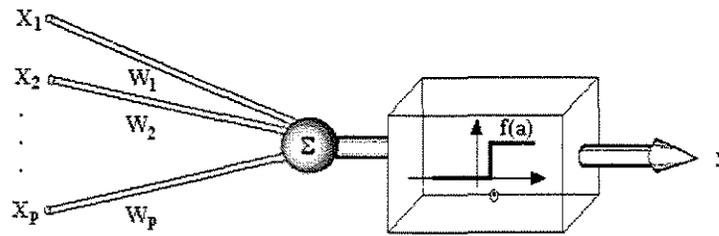


Figura 5.2 – Esquema de unidade McCulloch - Pitts.

Suponha que tenhamos p sinais (assumindo valores booleanos, 0 ou 1) de entrada X_1, X_2, \dots, X_p , seus respectivos pesos (com valores reais) w_1, w_2, \dots, w_p e ainda um limitador t . Neste modelo, o nível de atividade a é dado por:

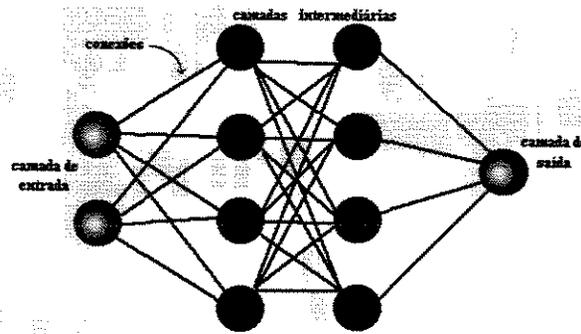
$$a = w_1X_1 + w_2X_2 + \dots + w_pX_p \quad (5.1)$$

A saída y é dada por:

$$y = 1, \text{ se } a \geq t; \text{ ou}$$

$$y = 0, \text{ se } a < t.$$

A maioria dos modelos de redes neurais possui alguma *Regra de Treinamento*, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, as redes têm a capacidade de “aprender” através de exemplos. As arquiteturas neurais (Figura 5.3) são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.



Organização em camadas.

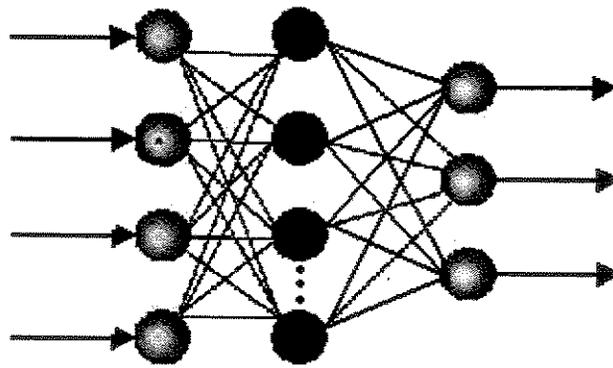


Figura 5.3 – RNA típica (4 entradas, n neurônios escondidos e 3 saídas).

Usualmente as camadas são classificadas em três grupos:

- **Camada de Entrada:** onde os padrões são apresentados à rede;
- **Camadas Intermediárias ou Escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas. Podem ser consideradas como extratoras de características;
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

Redes neurais artificiais também podem ser definidas como estruturas computacionais projetadas com o objetivo de explorar os princípios organizacionais existentes nos sistemas neurais biológicos. Por sua natureza, o estudo de redes neurais é multidisciplinar, envolvendo pesquisadores de diversas áreas, como neurofisiologia, psicologia, física, computação e engenharia (Haykin, 1999).

Uma RNA típica é composta por uma densa rede de elementos processadores (também chamados de neurônios artificiais), não lineares, dispostos em camadas e interconectados através de canais unidirecionais – as conexões – análogos às sinapses de um neurônio biológico (Figuras 5.1-5.3). Além de RNA, esses modelos também podem ser chamados de sistemas adaptativos, conexionismo, redes adaptativas, neurocomputadores ou processadores de distribuição paralela. A rede torna-se capaz de processar eficientemente dados numéricos, produzindo sinais de saída a partir de dados de entrada, após uma etapa chamada de *treinamento*, onde a RNA é submetida a diversos padrões com dados similares de entrada e saída. No treinamento (às vezes chamados de aprendizagem), os pesos e “biases” da rede são modificados.

Aplicações de RNA aos mais diversos campos da ciência e tecnologia são cada vez mais publicados na literatura e sua aplicação em problemas industriais crescem a cada ano (Haykin, 1990; Quantrille e Liu, 1991; De Souza Jr. 1993; Baughman e Liu, 1995; Von Zuben, 1996; Ng, 1997; Nørgaard *et al.*, 2000; Mujtaba e Hussaim, 2001).

5.2.2.1 - Motivação para a Utilização de Redes Neurais Artificiais

Redes Neurais Artificiais de processamento numérico, arquitetura em camadas e fluxo de informação com e sem realimentação, produzem estruturas de processamento de sinais com grande poder de adaptação e capacidade de representação não linear, além disso, são capazes de tratar dados com ruídos, típicos de situações industriais. A presença de realimentação cria a possibilidade de armazenar informações na forma de representações internas, além de introduzir dinâmica no processo. Sempre que métodos tradicionais, derivados da teoria de sistemas lineares, não apresentarem bom desempenho no tratamento de problemas envolvendo, por exemplo, aproximação de funções multivariáveis ou identificação e controle de sistemas dinâmicos, as RNA do tipo descrito acima despontam como alternativas bastante competitivas. Tais características devem-se principalmente à sua capacidade de representação de comportamentos não lineares arbitrários.

Redes neurais de várias camadas têm sido utilizadas em diversas aplicações tais como o reconhecimento de padrões e identificação de sistemas não lineares através da aproximação funcional. Teoricamente, a aplicação de redes neurais para aproximação funcional pode ser analisada utilizando-se o teorema de Weierstrass (Von Zuben, 1996). Basicamente, este teorema afirma que qualquer função contínua de valores reais definida em um intervalo limitado, pode ser aproximada por um polinômio. Se a função de ativação de cada elemento da rede for uma função contínua de valor real, ela também poderá ser aproximada por um polinômio e, conseqüentemente, a relação funcional de entrada-saída da rede poderá também ser aproximada por um polinômio. Assim sendo, será sempre possível definir uma RNA de múltiplas camadas para atuar como aproximação de um sistema não linear específico.

O estabelecimento de uma estrutura de RNA deve considerar tanto o número de amostras utilizadas na fase de treinamento, como a precisão desejada nas previsões a serem

feitas fora do conjunto utilizado para treinamento. O problema de se definir arquiteturas de redes neurais tem sido investigado por vários autores e as causas de imprecisão que devem ser consideradas para aproximação de sistemas não lineares são as seguintes (De Souza Jr., 1993):

- a) O número e a qualidade das amostras utilizadas para o treinamento pode ser insuficiente para captar a estrutura real da função ou comportamento do sistema a serem aproximados;
- b) A rede poderá estar sub-dimensionada, não possuindo um número suficiente de neurônios na camada intermediária e, portanto, a tolerância desejada não poderá ser atingida.

O item *a* pode ser considerado como um projeto de rede e, dessa forma, torna-se necessário um certo conhecimento do mapeamento a ser ensinado à rede. A segunda fonte de imprecisão pode ser evitada pela escolha correta da arquitetura da RNA. Para isso, são estabelecidos limites para o número de elementos das camadas intermediárias.

A determinação do número de amostras e da forma pela qual o mapeamento deve ser realizado, é o passo mais importante para que se atinja o sucesso no processo de treinamento da RNA. Mapeamentos bastante complexos podem ser aproximados por uma RNA mas, para que se obtenha uma generalização precisa, é necessário que se consiga captar a estrutura do sistema não linear pelas conexões da rede.

5.2.2.2 - O Modelo Matemático do Perceptron Multi Camada ou “Multilayer Perceptron” (MLP)

O *neurônio*, *nó* ou *unidade*, como também é chamado, é um elemento de processamento que toma um certo número de entradas, realiza uma soma ponderada e utiliza este resultado como argumento para uma função, a *função de ativação* (Figura 5.4). O neurônio pode ser representado matematicamente pela expressão:

$$y_i = f_i(h_i) = f_i\left(\sum_{j=1}^n w_{ij}\varphi_j + w_{i0}\right).$$

As entradas de um neurônio podem ser entradas externas ou as saídas de outro neurônio. O peso w_{i0} é chamado de *bias* e pode ser interpretado como um peso aplicado a uma pseudo entrada cujo valor é constante e geralmente igual a 1. A função de ativação f_i pode tomar qualquer forma, contudo geralmente é uma função monotônica, das quais as mais comumente utilizadas são as funções tangente hiperbólica, gaussiana, sigmoideal e linear.

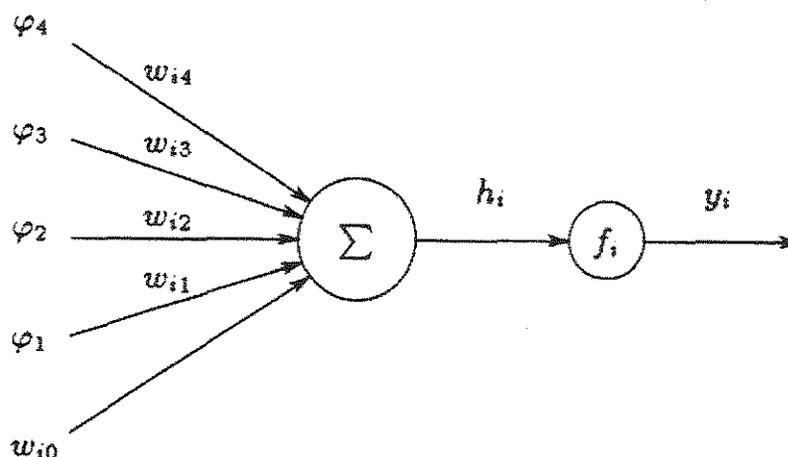


Figura 5.4 – O neurônio artificial.

Os neurônios podem ser combinados em uma rede de várias formas, contudo, o Perceptron Multi Camada (MLP) ou *Multilayer Perceptron* é provavelmente o tipo de RNA mais freqüentemente utilizado. A principal razão para isto é a sua habilidade de modelar desde mapeamentos simples até as relações funcionais mais complexas e não lineares. A rede MLP básica é construída ordenando-se os neurônios em camadas, de modo que cada neurônio em uma dada camada tome como entradas somente as saídas dos neurônios da camada anterior ou as entradas externas. Este tipo de estrutura gera as redes neurais do tipo *feedforward*. A Figura 5.5 ilustra uma RNA do tipo MLP do tipo *feedforward* totalmente conectada com três entradas, dois neurônios escondidos e dois neurônios na camada de saída. Os neurônios de cada camada apresentam diferentes funções de ativação. Geralmente utiliza-se a tangente hiperbólica como função de ativação para os neurônios da camada interna ($f_i(\bullet)$) e funções lineares para os neurônios da camada de saída ($F_i(\bullet)$).

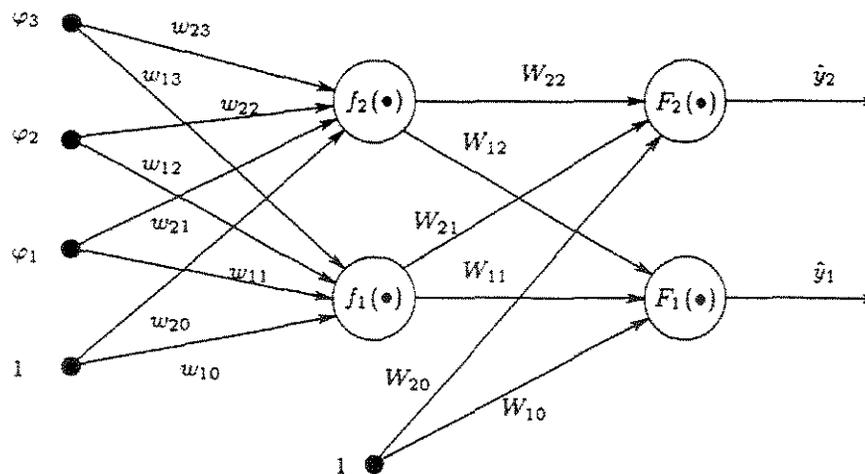


Figura 5.5 – Perceptron Multi Camada do tipo “*Feedforward*”.

A saída da RNA, \hat{y}_i , é representada por:

$$\hat{y}_i(t) = g_i[\varphi, \theta] = F_i \left[\sum_{j=1}^{n_h} W_{i,j} f_j \left(\sum_{l=1}^{n_e} w_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} \right]$$

onde θ especifica o vetor de parâmetros que contém todos os parâmetros ajustáveis da RNA, ou seja, os pesos e *biases* (w_{ij} , W_{ij}).

Para determinar os valores dos pesos, é preciso que se disponha de um conjunto de exemplos capaz de descrever como as saídas, \hat{y}_i , estão relacionadas com as entradas, φ_l . Este conjunto de exemplos também é conhecido como conjunto de *pares entrada/saída*. A tarefa de determinar os pesos de uma RNA a partir de um conjunto de exemplos é chamada de *treinamento* ou *aprendizado*. Neste processo os pesos são estimados a partir de exemplos de tal modo que a rede, de acordo com algum critério, modele a relação entrada/saída da forma mais acurada possível.

5.2.2.3 - Processos de Aprendizado

Uma RNA é especificada, principalmente através de sua topologia, pelas características dos neurônios e pelas regras de treinamento. A seguir, será apresentada a idéia geral do processo de treinamento das redes neurais.

A propriedade mais importante das redes neurais é a habilidade de aprender a partir de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o *treinamento*. O aprendizado ocorre quando a RNA atinge uma solução generalizada para uma dada classe de problemas.

Denomina-se *algoritmo de aprendizado*, um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma RNA se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- *Aprendizado Supervisionado*, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- *Aprendizado Não Supervisionado* (auto-organização), quando não existe uma agente externo indicando a resposta desejada para os padrões de entrada;
- *Reforço*, quando um crítico externo avalia a resposta fornecida pela rede.

Denomina-se *ciclo* uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos em um ciclo pode ser executada de dois modos:

- 1) *Modo Padrão*: A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.
- 2) *Modo Batelada*: Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

O treinamento supervisionado do modelo de rede Perceptron, consiste em ajustar os pesos e os *biases* de suas unidades para que a classificação desejada seja obtida. Para a adaptação do *bias* juntamente com os pesos podemos considerá-lo como sendo o peso associado a uma conexão, cuja entrada é sempre igual a 1 e adaptar o peso relativo a essa

entrada. Quando um padrão é inicialmente apresentado à rede, ela produz uma saída. Após medir a distância entre a resposta atual e a desejada, são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir esta distância. Este procedimento é conhecido como *Regra Delta* (Figura 5.6).

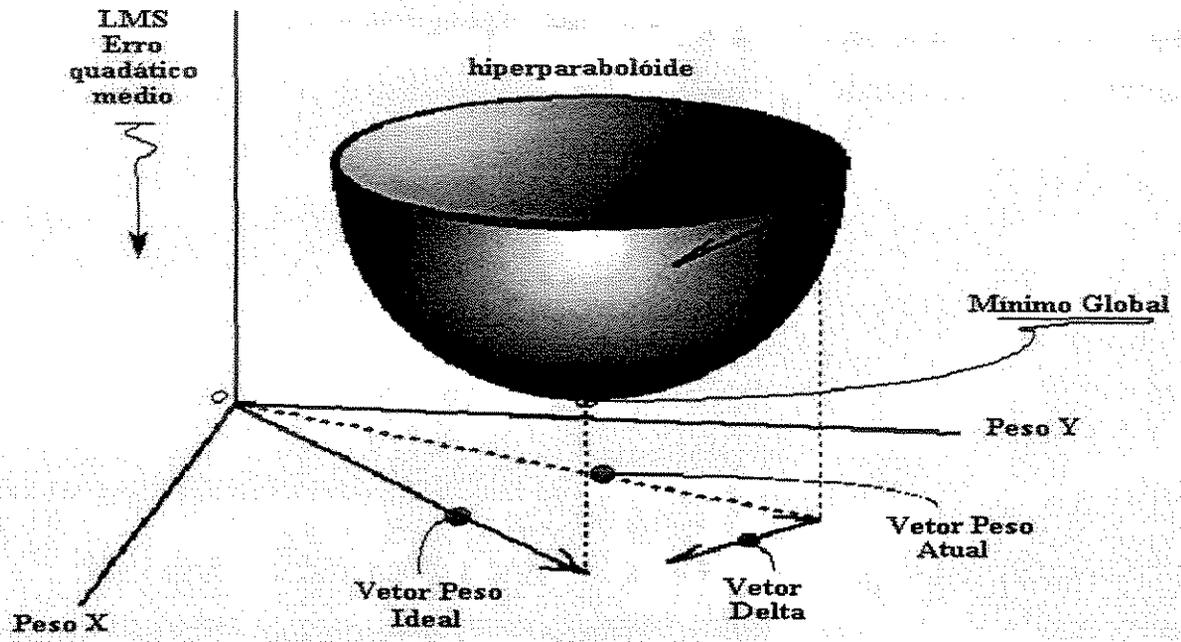


Figura 5.6 – A Regra Delta.

Deste modo, temos o seguinte esquema de treinamento:

- Iniciar todas as conexões com pesos aleatórios;
- Repita até que o erro E seja satisfatoriamente pequeno ($E = e$).
- Para cada par de treinamento (X, d) , faça:

Calcular a resposta obtida O ;

Se o erro não for satisfatoriamente pequeno, $E > e$, então:

- Atualizar pesos: $W_{novo} = W_{anterior} + \eta E X$

Onde:

O par de treinamento (X, d) corresponde ao padrão de entrada e a sua respectiva resposta desejada;

O erro E é definido como: Resposta Desejada - Resposta Obtida ($d - O$);

A taxa de aprendizado, η , é uma constante positiva que corresponde à velocidade do aprendizado. A Figura 5.7 ilustra esquematicamente este procedimento.

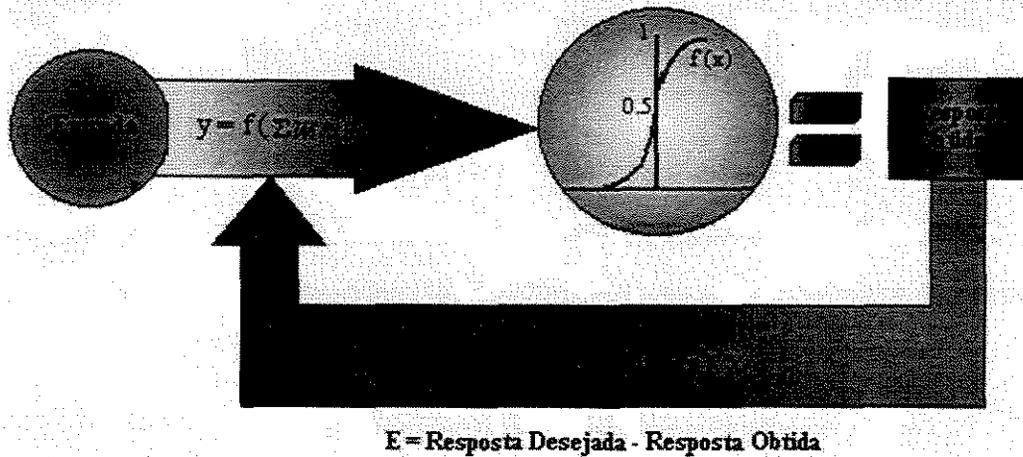


Figura 5.7 – Esquema de treinamento do Perceptron.

As respostas geradas pelas unidades são calculadas através de uma *função de ativação*. Existem vários tipos de funções de ativação, algumas delas estão representadas na Figura 5.8.

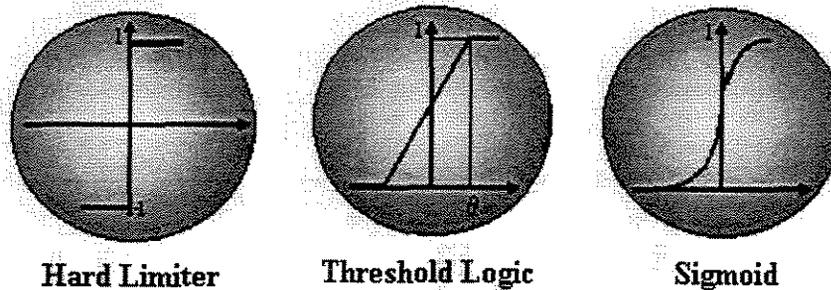


Figura 5.8 – Exemplos de funções de ativação dos neurônios da camada interna.

5.2.2.4 - O Treinamento do Perceptron Multi Camada (MLP)

Quando Redes Neurais Artificiais de **uma só camada** são utilizadas os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, ou seja não é possível a formação de uma representação interna. Neste caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento. Tal restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva o sistema à incapacidade de aprender importantes

mapeamentos. Como resultado, padrões de entrada com estruturas similares que levem a saídas diferentes não podem ser mapeados por redes sem representações internas, isto é, sem camadas intermediárias. Um exemplo clássico deste caso é a função *ou-exclusivo* (XOR).

MINSKY e PAPERT (1969) analisaram matematicamente o **Perceptron** e demonstraram que **redes com uma camada** não são capazes de solucionar problemas que não sejam linearmente separáveis. Como não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre suscetíveis a essa limitação.

Contudo, o desenvolvimento do algoritmo de treinamento “**backpropagation**”, por Rumelhart, Hinton e Williams em 1986, precedido por propostas semelhantes ocorridas nos anos 70 e 80, mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizado atualmente, as **Redes Perceptron Multi Camadas** (MLP), treinadas com o algoritmo *backpropagation*.

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

Se existirem as conexões certas entre as unidades de entrada e um conjunto suficientemente grande de unidades intermediárias (neurônios), pode-se sempre encontrar a representação que irá produzir o mapeamento correto da entrada para a saída através das unidades intermediárias. Também foi provado que uma RNA do tipo MLP com apenas uma camada intermediária, contendo um número suficiente de neurônios, é capaz de aproximar qualquer função contínua e limitada.

5.2.2..5 - O Algoritmo Backpropagation

Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma seqüência de dois passos. No primeiro passo (Figura 5.9), um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se o valor da saída calculada não estiver correto, o erro é calculado. Este erro é então propagado a partir da camada de saída até a camada de entrada (daí o nome “backpropagation”), e os pesos das conexões dos neurônios da camada interna vão sendo modificados conforme o erro é retropropagado.

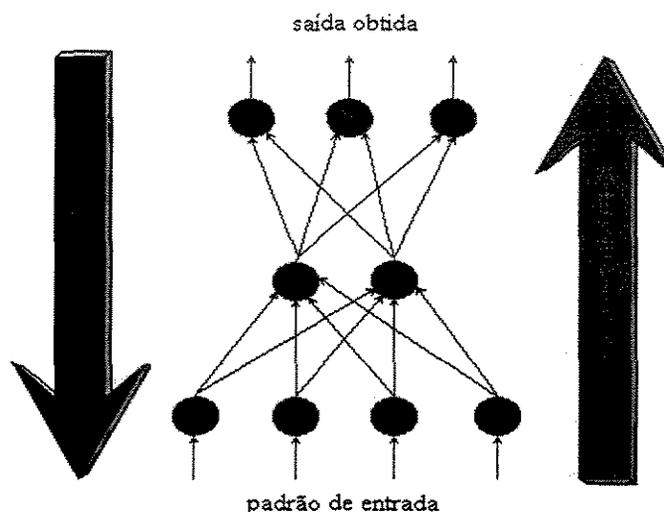


Figura 5.9 – Esquema de treinamento backpropagation.

As redes que utilizam *backpropagation* trabalham com uma variação da *Regra Delta* (Figura 5.6), apropriada para redes multi-camadas: a *Regra Delta Generalizada*. A *Regra Delta* padrão, a rigor, implementa um gradiente descendente no quadrado da soma do erro para funções de ativação lineares. Redes sem camadas intermediárias podem resolver problemas onde a superfície de erro tem a forma de um parabolóide com apenas um mínimo. Entretanto, a superfície do erro pode não ser tão simples, como a ilustrada na figura abaixo, e suas derivadas mais difíceis de serem calculadas. Nestes casos devem ser utilizadas redes com camadas intermediárias. Ainda assim, as redes ficam sujeitas aos problemas de mínimos locais.

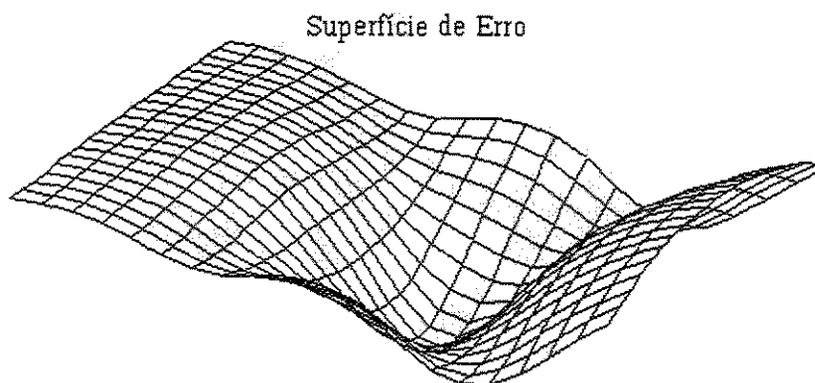


Figura 5.10 – Exemplo de superfície de erro.

A *Regra Delta Generalizada*¹ funciona quando são utilizados neurônios com uma função de ativação não linear na rede (que são funções diferenciáveis e não decrescentes). Note que a função *threshold* não se enquadra nesse requisito. As funções de ativação amplamente utilizadas nestes casos são as funções do tipo *sigmoid*, $f(a) = \frac{1}{1 + e^{-a}}$, onde a representa a *atividade* do neurônio representada pela Equação (1).

Um outro parâmetro, a *taxa de aprendizado* “ η ”, é uma constante de proporcionalidade no intervalo [0,1], pois este procedimento de aprendizado requer apenas que a mudança no peso seja proporcional a η . Entretanto, o verdadeiro *Gradiente Descendente* requer que sejam tomados passos infinitesimais. Assim quanto maior for essa constante maior será a mudança nos pesos, aumentando a velocidade do aprendizado, o que por outro lado, pode levar à oscilação do modelo na superfície de erro. O ideal seria utilizar a maior taxa de aprendizado possível que não levasse à oscilação, resultando em um aprendizado mais rápido.

O treinamento das redes MLP com *backpropagation* pode demandar muitos passos no conjunto de treinamento, resultando um tempo de treinamento consideravelmente longo. Se for encontrado um mínimo local, o erro para o conjunto de treinamento pára de diminuir e estaciona em um valor maior que o aceitável. Uma maneira de aumentar a taxa de aprendizado sem levar à oscilação é modificar a *Regra Delta Generalizada* para incluir o

¹ Algoritmo utilizado no “software” fornecido pelo LOPCA.

termo *momentum*, uma constante que determina o efeito das mudanças passadas dos pesos na direção atual do movimento no espaço de pesos. Desta forma, o termo *momentum* leva em consideração o efeito de mudanças anteriores de pesos na direção do movimento atual no espaço de pesos. O termo *momentum* torna-se útil em espaços de erro que contenham longas gargantas, com curvas acentuadas ou vales com descidas suaves, como o apresentado na Figura 5.10.

5.2.2.6 - A Regra Delta Generalizada

Considere dois neurônios i e j situados em camadas adjacentes como mostrado na Figura 5.11. Estes neurônios fazem parte de uma rede onde N_o é a camada de saída da rede e p o vetor de entrada dos padrões. A saída do neurônio j , a_j , é a entrada do neurônio i , cuja saída é a_i . Sendo assim, o peso relativo à conexão entre i e j é w_{ij} . O parâmetro θ_i é o *bias* e funciona como um neurônio extra acoplado a cada neurônio da rede com o objetivo de permitir uma convergência mais rápida do processo de treinamento.

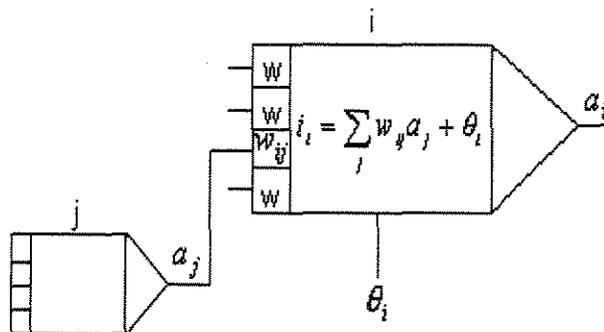


Figura 5.11 – Conexão dos neurônios i e j .

A atividade do neurônio i no tempo t é dada por:

$$i_i^p(t) = \sum_j w_{ij}(t) a_j^p(t) + \theta_i(t) \quad (5.2)$$

A saída do neurônio i no tempo $t+1$ é dada por uma função da atividade no tempo t :

$$a_i^p(t+1) = f_i \left(\sum_j w_{ij}(t) a_j^p(t) + \theta_i(t) \right) \quad (5.3)$$

Como visto anteriormente a função mais utilizada nestes casos é a do tipo sigmoidal:

$$a_i^p = \frac{1}{1 + e^{-i^p}} \quad (5.4)$$

Calcula-se então a atividade para todos os neurônios até chegar à camada de saída N_o , onde se obtém a resposta. A correção dos pesos é feita retropropagando o erro. A regra para correção dos pesos é dada por:

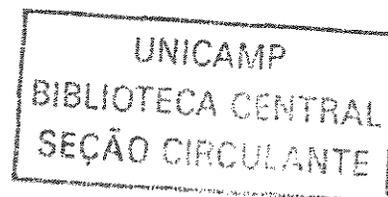
$$w_{novo} = w_{anterior} + \Delta w \quad (5.5)$$

Utilizando-se o método gradiente para minimizar o erro em relação ao peso, o gradiente do erro deve ser calculado. O erro E^p é definido como o erro quadrático para o padrão p no neurônio de saída, e é dado por:

$$E^p = \frac{1}{2} \sum_{i=1}^{N_o} (d_i^p - a_i^p)^2 \quad (5.6)$$

onde d_i^p é a resposta desejada (padrão) e a_i^p a resposta obtida da rede. O erro total é $E = \sum_p E^p$, e devera ser minimizado. O Δw , para os neurônios i e j , é dado pela relação:

$$\Delta_p w_{ij} = -\gamma \frac{\partial E^p}{\partial w_{ij}} \quad (5.7)$$



A relação mostrada na equação acima é derivada do método do gradiente, onde se parte de um ponto arbitrário e caminha-se na superfície de erro em direção ao ponto de mínimo. A evolução é sempre no sentido oposto ao gradiente naquele ponto. A Figura 5.10 mostra um exemplo de superfície de erro. A constante γ determina o tamanho do passo de correção.

Deseja-se obter uma expressão para $\frac{\partial E^p}{\partial w_{ij}}$. Pode-se aplicar a regra da cadeia e obter:

$$\frac{\partial E^p}{\partial w_{ij}} = \frac{\partial E^p}{\partial i_i^p} \cdot \frac{\partial i_i^p}{\partial w_{ij}} \quad (5.8)$$

Derivando-se a Equação (5.2) pode-se ver que:

$$\frac{\partial i_i^p}{\partial w_{ij}} = a_j^p \quad (5.9)$$

Definindo: $\delta_i^p = -\frac{\partial E^p}{\partial i_i^p}$, tem-se que:

$$\Delta_p w_{ij} = \gamma \delta_i^p a_j^p \quad (5.10)$$

Agora deve-se obter uma relação para δ_i^p . Pode-se escrever que:

$$\delta_i^p = -\frac{\partial E^p}{\partial i_i^p} = -\frac{\partial E^p}{\partial a_i^p} \cdot \frac{\partial a_i^p}{\partial i_i^p} \quad (5.11)$$

Mas pela Equação (5.3) podemos ver que $\frac{\partial a_i^p}{\partial i_i^p} = f'(i_i^p)$, sendo então uma simples derivada da função sigmoideal (se for esta a função utilizada). Para se determinar o primeiro termo

$\frac{\partial E^p}{\partial a_i^p}$ deve-se considerar dois casos:

O primeiro caso considera que o neurônio i faz parte da camada de saída, assim segundo a definição de E^p , tem-se:

$$\frac{\partial E^p}{\partial a_i^p} = -(d_i^p - a_i^p) \quad (5.12)$$

Temos então que δ_i^p é dado por:

$$\delta_i^p = (d_i^p - a_i^p) f'(i_i^p) \quad (5.13)$$

No segundo caso, o neurônio não faz parte da camada de saída e sim de uma camada intermediária qualquer. Assim, aplicando a regra da cadeia e utilizando h para representar as camadas da RNA:

$$\frac{\partial E^p}{\partial a_i^p} = \sum_{h=1}^{N_0} \frac{\partial E^p}{\partial i_h^p} \frac{\partial i_h^p}{\partial a_i^p} = \sum_{h=1}^{N_0} \frac{\partial E^p}{\partial i_h^p} \frac{\partial}{\partial a_i^p} \sum_{k=1}^{N_h} w_{hk} a_k^p = \sum_{h=1}^{N_0} \frac{\partial E^p}{\partial i_h^p} w_{hi} = -\sum_{h=1}^{N_0} \delta_h^p w_{hi} \quad (5.14)$$

Com esta relação obtém-se uma outra equação para δ_i^p :

$$\delta_i^p = f'(i_i^p) \sum_{h=1}^{N_0} \delta_h^p w_{hi} \quad (5.15)$$

A partir das equações (5), (13) e (14) pode-se criar um processo recursivo para a atualização dos pesos, que é a idéia básica da *Regra Delta Generalizada* para uma rede *Feedforward* com função de ativação não linear.

A seguir, será apresentado um exemplo numérico da implementação da Regra Delta Generalizada. Maiores detalhes sobre a implementação computacional dos algoritmos

Backpropagation e Regra Delta Generalizada podem ser obtidos em Baughman e Liu (1995) e Quantrille e Liu (1991).

Exemplo de Aplicação da Regra Delta Generalizada

Considere a RNA com três camadas, A, B, C, mostrada na Figura 5.12.

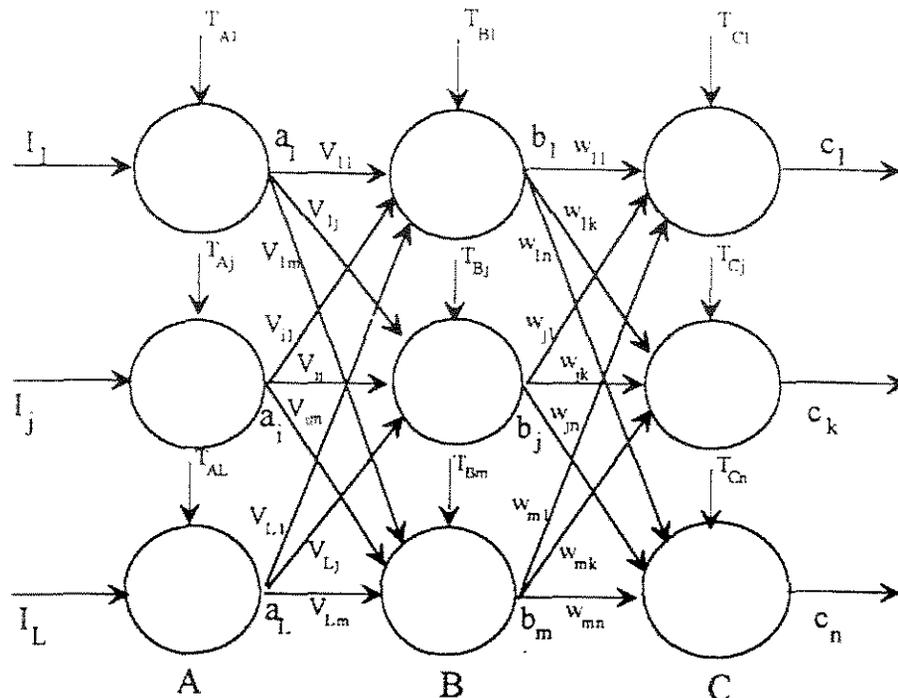


Figura 5.12 – Rede MLP com três camadas.

O vetor de entradas I alimenta a camada A, que tem L neurônios a_i ($i = 1$ a L) com um neurônio para cada entrada. A camada B, que é a camada interna ou escondida, tem m neurônios, b_j ($j = 1$ a m), cuja quantidade pode ser ajustada para facilitar a convergência da rede. A camada C, que é a camada de saída, tem n neurônios, c_k ($k = 1$ a n), com um neurônio para cada saída.

O peso de conexão entre o $i^{\text{ésimo}}$ neurônio da camada A e o $j^{\text{ésimo}}$ neurônio da camada B é denotado v_{ij} e o peso entre o $j^{\text{ésimo}}$ neurônio da camada B e o $k^{\text{ésimo}}$ neurônio da camada C é denotado w_{jk} . Cada neurônio tem um valor limitante interno (threshold ou bias) T_{Ai} , T_{Bj} e T_{Ck} para cada camada, respectivamente. O threshold interno controla a ativação de

cada neurônio. O neurônio calcula o somatório ponderado de todos os $(w_{jk} a_i)$ e então calcula a ativação total, x_j , somando o valor do bias:

$$x_j = \sum_i w_{ij} a_i + T_j \quad (5.16)$$

5.3 - Descrição do Procedimento e dos Critérios.

5.3.1 - Coleta e separação de dados de processo

Esta etapa envolve a coleta e o tratamento dos dados referentes às variáveis diretamente envolvidas no processo. O objetivo é obter um histórico representativo de todas as condições operacionais passíveis de ocorrer na planta.

Os dois primeiros passos do processo de desenvolvimento de redes neurais artificiais são a coleta de dados relativos ao problema e a sua separação em um conjunto de treinamento e um conjunto de testes. Esta tarefa requer uma análise cuidadosa sobre o problema para minimizar ambigüidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições limites do domínio do problema. Um ponto de destacada importância está relacionado à confiabilidade das medidas que serão apresentadas à RNA. Uma RNA treinada com dados oriundos de medidas incertas certamente produzirá um *Soft-Sensor* de má qualidade (a rede “aprenderá” erros).

Normalmente, os dados coletados são separados em duas categorias: *i)* dados de treinamento, que serão utilizados para o treinamento da rede e, *ii)* dados de teste, que serão utilizados para verificar o desempenho da rede sob condições reais de utilização.

Depois de determinados estes conjuntos, eles são, geralmente, colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Além disso, é necessário pré-processar estes dados através de normalizações,

escalonamentos e/ou conversões de formato para torná-los mais apropriados à sua utilização na rede².

5.3.2 - Configuração da rede

O terceiro passo é a definição da configuração da rede, que pode ser dividido em três etapas:

- 1) Seleção do paradigma neural apropriado à aplicação (MLP, RBF, etc.).
- 2) Determinação da topologia da rede a ser utilizada: O número de camadas, o número de unidades em cada camada, etc.
- 3) Determinação de parâmetros do algoritmo de treinamento e funções de ativação. Este passo tem um grande impacto na performance do sistema resultante.

Existem metodologias, na condução destas tarefas. Normalmente estas escolhas são feitas de forma empírica. A definição da configuração de redes neurais é ainda considerada uma arte, o que pode demandar bastante tempo e requerer grande experiência dos projetistas de modo que um conhecimento aprofundado do processo de interesse é de grande utilidade na etapa de configuração do *Soft-Sensor*. No entanto é possível, através da implementação de algoritmos mais sofisticados (Campello et al 2003) obter configurações mais adequadas das redes neurais.

5.3.3 - Treinamento das redes neurais

O quarto passo é o treinamento da rede. Nesta fase os pesos das conexões serão ajustados segundo os critérios do algoritmo de treinamento escolhido. É importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento. Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura.

² O “software” fornecido pelo LOPCA foi projetado para fazer automaticamente as normalizações e escalonamentos necessários.

Quanto ao modo de treinamento, na prática é mais utilizado o modo padrão devido ao menor armazenamento de dados, além de ser menos suscetível ao problema de mínimos locais, devido à pesquisa de natureza estocástica que realiza. Por outro lado, no modo batelada tem-se uma melhor estimativa do vetor gradiente, o que torna o treinamento mais estável. A eficiência relativa dos dois modos de treinamento depende do problema que está sendo tratado.

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. O critério de parada do algoritmo “backpropagation” não é bem definido, e geralmente é utilizado um número máximo de ciclos ou iterações. Contudo, devem ser consideradas a taxa de erro médio por ciclo e a capacidade de generalização da rede. Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de “*over-training*” ou sobre-ajuste, ou seja, a rede se especializa demais no conjunto de dados do treinamento e perde a capacidade de generalização. O treinamento deve ser interrompido quando a rede ainda apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena.

Isto pode ser feito da seguinte forma: Interrompe-se o treinamento de tempos em tempos e realizam-se testes do desempenho da rede com uma pequena parte do arquivo de dados para validação. Deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima, ou seja, deve-se continuar treinando a rede com uma dada configuração enquanto o erro de validação continuar decrescendo.

5.3.4 - Testes off-line

Após a fase de treinamento, inicia-se a fase de validação que será dividida em duas partes:

- i) Validação da rede com os dados históricos do processo previamente separado do arquivo de dados inicial; e
- ii) Teste com dados atuais de processo, porém ainda no modo “off-line”.

Durante a fase de teste da rede o conjunto de teste é utilizado para determinar o desempenho da rede com dados que não foram previamente utilizados. O desempenho da rede medida nesta fase é uma boa indicação de sua performance real. Devem ser considerados ainda outros testes como análise do comportamento da rede utilizando entradas relacionadas a condições especiais de operação e análise dos pesos atuais da rede, pois se existirem valores muito pequeno, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas (*prunning*). De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve “*over-training*” ou sobre-ajuste da rede.

5.4 - Implantação do Modelo e Acompanhamento.

5.4.1 - Utilizando a MLP

Depois que a rede estiver treinada e o erro estiver em um nível satisfatório, ela poderá ser utilizada como uma ferramenta para classificação de novos dados. Para isto, a rede deverá ser utilizada apenas no modo progressivo (*feedforward*). Ou seja, novas entradas (desconhecidas da rede) são apresentadas à camada de entrada, processadas nas camadas intermediárias e os resultados são apresentados na camada de saída, assim como no treinamento, porém agora sem a retropropagação do erro. A saída fornecida é o modelo dos dados (mapeamento entrada/saída) segundo a interpretação da rede (Figura 5.13).

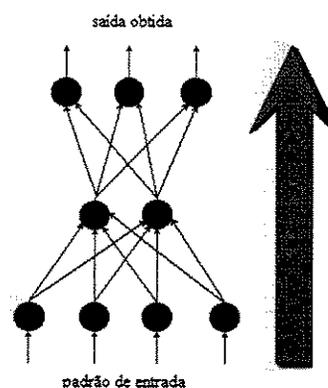


Figura 5.13 – Utilização da rede MLP.

5.4.2 - Testes on-line e Integração ao Ambiente de Produção

Esta é a fase final de testes, onde o *Soft-Sensor* já poderá estar integrado ao processo através do SETCIM e ter seus resultados comparados com os valores reais da viscosidade fornecidos pelos sensores e/ou análises de laboratório.

Caso os resultados ainda não estejam satisfatórios, deve-se considerar uma nova etapa de treinamento manipulando-se a configuração da rede ou mesmo modificando a base de dados de processo.

No caso da rede treinada ser avaliada positivamente, ela pode ser integrada ao sistema do ambiente operacional da aplicação através do SETCIM, que pode fornecer as facilidades de utilização do *Soft-Sensor* como interface conveniente e as facilidades de aquisição de dados através de planilhas eletrônicas, interfaces com unidades de processamento de sinais, ou arquivos padronizados. Além disso, o Engenheiro de Processo deve periodicamente monitorar o seu desempenho e fazer a manutenção da rede no caso de novas condições operacionais. Outras melhorias poderão ainda ser sugeridas quando os usuários estiverem mais familiarizados com o sistema.

5.5 - Integração com o "Setcim".

Para integrar o soft-sensor com o Setcim, atualizando os dados em tempo real com o processo, foi desenvolvida uma tarefa externa, conforme descrito no capítulo anterior, com a seguinte seqüência:

1. Conversão do programa de RNA desenvolvido em Fortran para linguagem C (em função do compilador disponível na AlphaServer);
2. Alteração do programa, incluindo as bibliotecas do Setcim;
3. Criação de novas linhas no programa, para desenvolver uma nova estrutura de banco de dados, para armazenar as entradas e saídas de dados;
4. Criação da Tarefa Externa, compilando o programa;
5. TSK_SSNS (nome da tarefa criada) - responsável pela execução do softsensor;
6. Criação de um *Record* para registrar os valores da viscosidade no CLP;

5.5.1 - Descrição do funcionamento da Integração com Setcim

A figura 5.14 mostra o esquema da integração do Soft-Sensor com o Setcim.

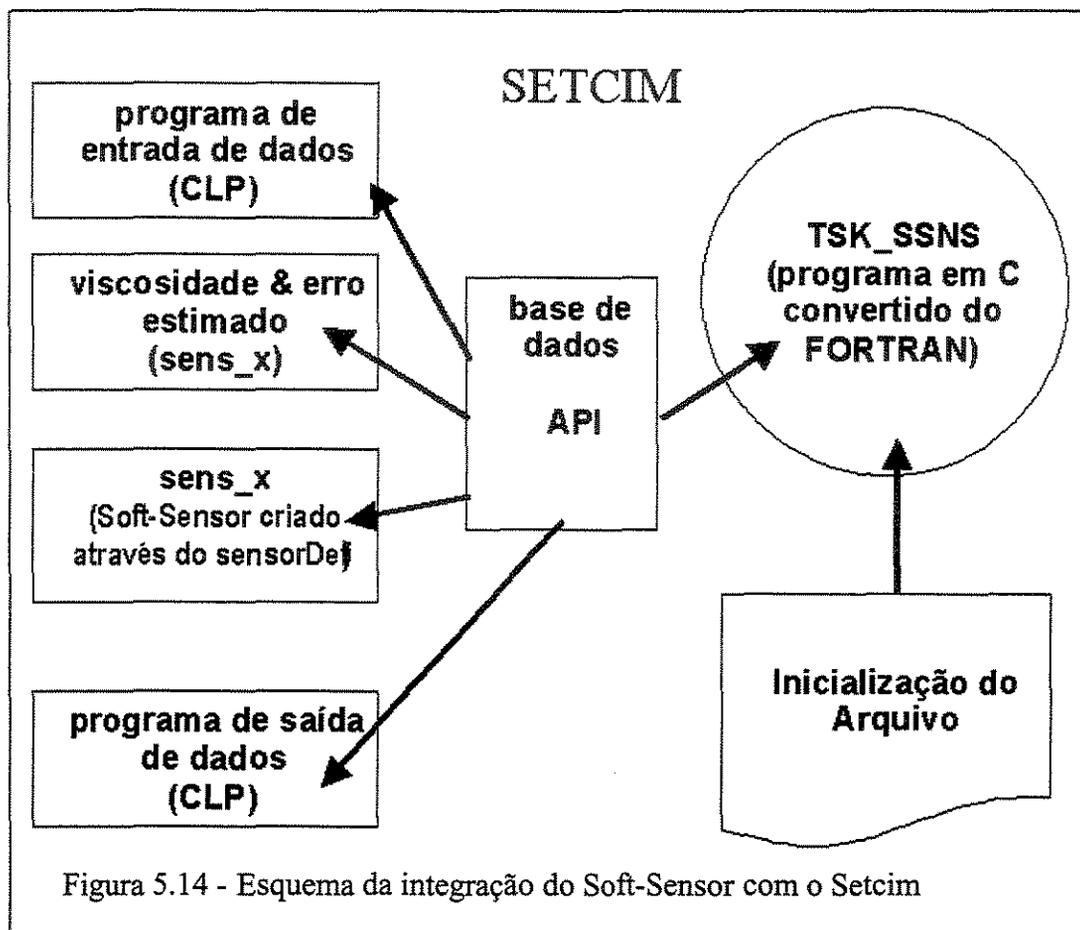


Figura 5.14 - Esquema da integração do Soft-Sensor com o Setcim

Primeiramente, inicializa-se a tarefa externa através de um arquivo de comando, ação esta que só se faz uma única vez, criando o processo TSK_SSNS, que passa a rodar junto com os outros processos interligados com o Setcim. Em seguida, são criados os *records* na base de dados do Setcim. Os primeiros *records* a serem criados são os que vão armazenar os valores gerados pelo Soft-Sensor, viscosidade estimada (SVT-5.1), erro percentual (E100-5.1) e o erro absoluto (EABS-5.1). Estes *records* são criados com o mesmo tipo de definição utilizada para criar variáveis analógicas do CLP (RSAnalogdef), que é do tipo *float* (valores decimais). E, por fim, é criado o *record* que irá realizar o papel de interligação entre o Setcim e o programa de RNA, o *record* Sens-X. Este *record* é

criado usando um tipo especial de definição que foi elaborada justamente para esta função, que é o `Sensdef`. Os campos do `Sens-X`, devem ser preenchidos após todas as informações já estarem definidas, tais como:

- Nome da tarefa externa (`TSK_SSNS`);
- Tempo de atualização da base de dados;
- Nome do arquivo de pesos;
- Número de informações passadas ($n+1$);
- Nome para viscosidade estimada;
- Nome para os erro absoluto;
- Nome para o erro percentual;
- Numero de variáveis (entrada mais saída)
- Variáveis de entrada
- Variável de saída (última a ser digitada)

A figura 5.15 mostra a estrutura do Record `Sens-X`. O intervalo de ativação é a cada 1 minuto (`RESCHEDULE_INTERVAL`), o arquivo de pesos, `pesos-X.txt`, está no diretório `setcim\group250 (! FILE_NAME)`, o número de informações passadas é zero (`NUMBER OF TREND VALS`), portanto 1, as variáveis de saída da RNA (viscosidade e erros), as variáveis de entrada (`9 #DATA_BASE_RECORDS`) até $n-1$ e a variável de saída para comparação da RNA (VT-5.1).

Após ter preenchido todos os campos do `Sens-X`, o mesmo passa a executar o programa de RNA a cada intervalo de tempo conforme estabelecido no campo `RESCHEDULE_INTERVAL`, tomando os valores da base de dados (`9 #DATA_BASE_RECORDS`), como se fosse um arquivo de dados, para testar o arquivo de pesos e retornar os valores calculados. Da forma que foi desenvolvido o programa, é possível construir quantos sensores forem necessários, usando a mesma tarefa `TSK_SSNS`.

Cada sensor virtual deverá ter seus campos preenchidos com valores correspondentes a suas variáveis, desde o arquivo de pesos até a variável de saída.

Definition Record		<u>SoftSensorDef</u>	
	Sens-X		NAME
	TSK_SSNS		EXTERNAL_TASK_RECORD
	29-JAN-03 16:02:00.0		SCHEDULE_TIME
	+000:01:00.0		RESCHEDULE_INTERVAL
setcim: [group250] pesos-X.txt		!	FILE_NAME
		1	NUMBER OF TREND VALS
SVT-5.1	INPUT VALUE		ESTIMATED VISCOSITY
EABS-5.1	INPUT VALUE		ERROR ABSOLUTE
E100-5.1	INPUT VALUE		ERROR PERCENTAGE
		9	#DATA_BASE_RECORDS
	TT-2.1	1	RECORD_NAME
	TT-3.1	2	RECORD_NAME
	TT-4.2	3	RECORD_NAME
	PT-4.3.1	4	RECORD_NAME
	PT-4.3.2	5	RECORD_NAME
	TT-5.1	6	RECORD_NAME
	PT-5.1	7	RECORD_NAME
	FT-4.1	8	RECORD_NAME
	VT-5.1	9	RECORD_NAME

Figura 5.15 – Estrutura do Record Sens-X

Com o que foi descrito acima, é possível visualizar a viscosidade calculada e a viscosidade real simultaneamente em um gráfico no Supervisório. Portanto, para que se possa realizar o controle da mesma, numa eventual falha do viscosímetro, é necessário a criação de um novo *record*, neste caso, registrado para o CLP. Este *Record* (SVT-5.1E) recebe o valor da viscosidade calculada e o envia para o CLP todas as vezes que este for atualizado, usando uma outra tarefa externa, já desenvolvida anteriormente para toda a planta, sem a necessidade de um novo desenvolvimento. A definição utilizada para criação

deste *record* é a TcdDef, definição de telecomando para variáveis analógica (tipo *float*). A Figura 5.16, mostra a estrutura de um *record* de escrita do Supervisório para o CLP.

Onde se tem que:

Plant Area	Nome da linha de produção (Poderá ser qualquer linha da fábrica)
Name	Nome da Variável que envia o valor para o CLP
Description	Descrição da função da variável
Value Format	Formato do campo (neste exemplo é um valor decimal com duas casas)
Value	O valor atual
Value_Offset	Endereço da palavra no CLP que vai receber o valor
Last_update	Data da última atualização
Inibição	Correspondente ao alarme
Razão_Inib	Estado do alarme
Var_Link	Nome do CLP da rede e do endereço do arquivo.
Wait_For_Cos_Field	Escreve no CLP, todas as vezes que houver uma atualização.

Definition Record	TcdFDef
	LINHA D PLANT AREA
	SVT-5.1E NAME
Escreve Viscosidade Virtual no PLC	DESCRIPTION
	F 7. 2 VALUE FORMAT
	1285.5 VALUE
	153 VALUE_OFFSET
29-JAN-03 16:01:36.0	LAST_UPDATE
	OFF INIBICAO
	OK RAZAO_INIB
	LINKFDUPETPROCE VAR_LINK
SVT-5.1E	LAST_UPDATE WAIT_FOR_COS_FIELD

Figura 5.16 – Estrutura do Record SVT-5.1E

5.6 - Conclusões

Neste capítulo, foram apresentadas as principais informações para construção de um sensor virtual, de funcionamento *on line* com o processo, utilizando uma rede de CLPs, um sistema supervisório e um programa de aplicação de RNA. É importante salientar que a utilização de RNA para construção de um sensor virtual implica em trabalhar com uma base de dados de treinamento bem alterada nas faixas operacionais de domínio da entrada;

ou seja, que contenha o máximo de situações diferentes do processo possível, no que tange a amplitude e frequência. Visto que a RNA apresenta um mecanismo de aprendizado proveniente de exemplos. A figura 5.17 mostra o esquema do sensor virtual.

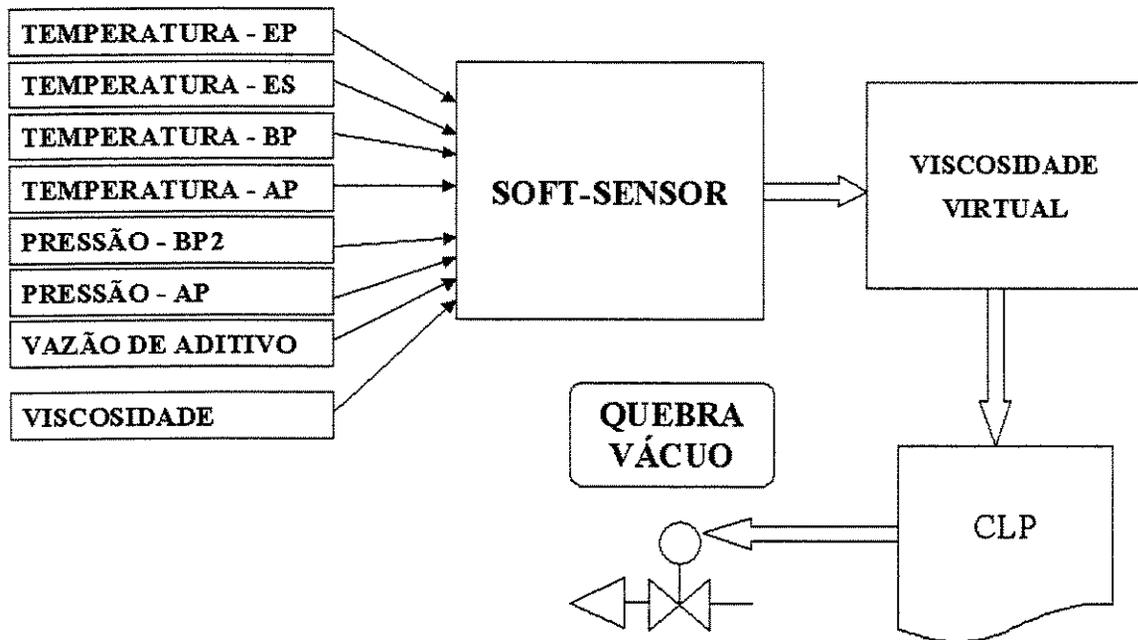


Figura 5.17 Esquema do sensor virtual

No capítulo seguinte apresentam-se resultados do trabalho, critérios utilizados e procedimentos adotados.

CAPÍTULO 6

RESULTADOS DA IMPLEMENTAÇÃO DO SOFT-SENSOR

6.1 - Geração da base de dados

No tocante a obtenção de dados industriais, adotou-se um procedimento rigoroso para aumentar a confiabilidade dos dados: primeiramente foi selecionada uma equipe de trabalho multidisciplinar de diversos departamentos da fábrica envolvidos com o viscosímetro (pesquisa e desenvolvimento, produção, engenharia de manutenção e laboratório). A tarefa principal desta equipe foi na padronização das informações haja visto as diferenças de escalas empregadas nos viscosímetros de cada linha de produção. Segundo, alguns cuidados foram tomados para eliminar todos os possíveis problemas, tais como: limpeza do capilar, troca de bombas, aferição do transmissor de pressão e acerto das escalas de conversão bem como outros problemas.

Desta forma, após as certificações de manutenção e operacionalidade adequada dos viscosímetros, uma base de dados de treinamento foi gerada.

6.2 - Treinamento da RNA

Para treinamento da rede neural, 6495 padrões (conjunto de dados entrada-saída) foram utilizados, representando um tempo de produção contínuo de dois meses. Antes de serem empregados para o treinamento da rede, o conjunto de dados passou por uma filtragem inicial, devido as paradas da planta no mesmo período considerado para a realização de manutenção de equipamentos. O critério utilizado para filtrar a base de dados foi a especificação do processo que considera um intervalo de confiança da média de três desvios padrões.

Para o teste da rede neural, foram utilizados dois procedimentos: 1) objetivando-se conseguir uma informação inicial da correlação obtida, foi utilizada a própria base de dados

empregada na geração do arquivo de pesos. 2) funcionamento *on-line* ao processo, podendo-se analisar o desempenho da rede em comparação ao verdadeiro viscosímetro.

Analisando-se o erro médio quadrático durante o processo de treinamento para diversas topologias de rede, verificou-se que uma rede neural com uma camada intermediária, sem nenhuma informação passada e com 9 neurônios, é capaz de fornecer bons resultados para o caso considerado no presente trabalho.

Para se analisar a qualidade de treinamento e teste da rede neural elaborada, alguns gráficos de saída da rede (estimativa) *versus* a saída desejada (alvo) foram realizados, onde o valor de correlação indica a qualidade do treinamento da rede.

As figuras 6.1, 6.2, 6.3, 6.4, 6.5 e 6.6 mostram resultados do comportamento da rede neural em relação ao viscosímetro, utilizando-se o conjunto de dados de treinamento para validação.

As figuras 6.7, 6.8 e 6.9 mostram os resultados de validação do *Soft-Sensor* em tempo real, considerando-se uma base de dados diferente da base de treinamento. Este teste apresenta maior importância pois a execução do mesmo ocorre *on-line* com o processo, ou seja, o programa é validado a cada novo valor do *Soft-Sensor*.

Como o programa contempla o cálculo do erro absoluto e erro relativo a cada novo valor e como a rede apresentou no teste de validação de dados de treinamento um erro menor ou igual 5 poise e no teste em tempo real um valor menor ou igual a 10 poise, um alarme diagnosticando uma possível falha sempre que o erro absoluto for superior a 50 poise. Assim, este alarme sinaliza à equipe de produção a enviar uma amostra para o laboratório, com o propósito de averiguar se a variação é proveniente do *Soft-Sensor* ou do viscosímetro.

Um gráfico de tendência para registrar o comportamento do erro, também esta sendo disponibilizado para a produção, caso ela queira fazer uma análise mais criteriosa antes de enviar mais amostras para o laboratório.

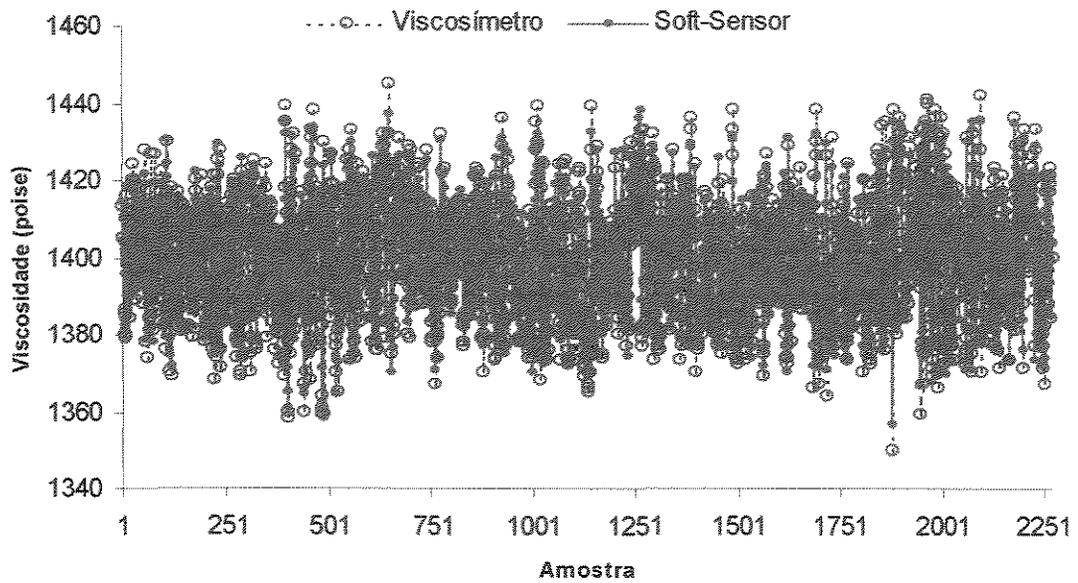


Figura 6.1 – Viscosímetro versus Soft-Sensor

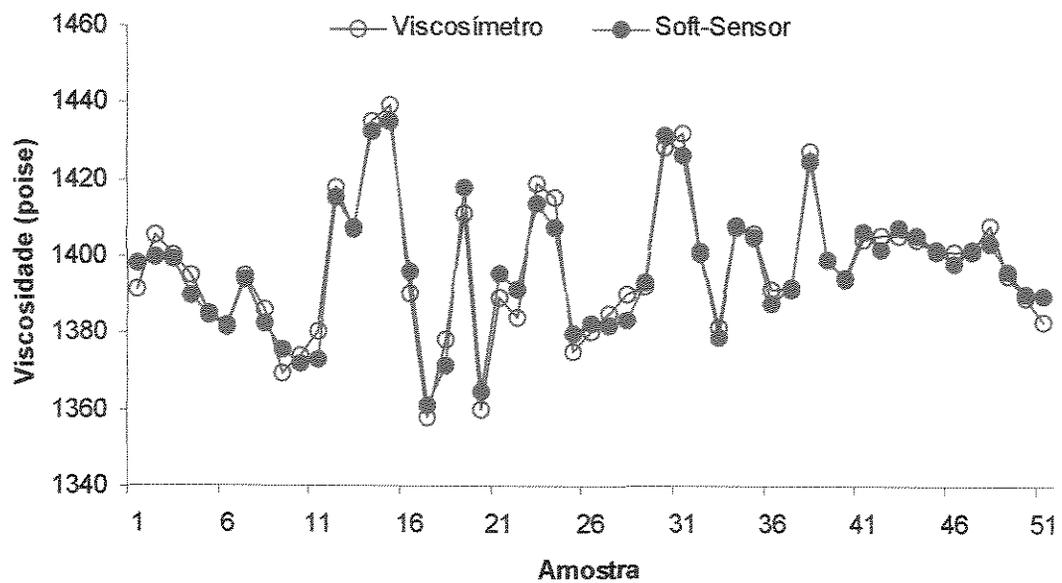


Figura 6.2 – “Zoom” da Figura 6.1

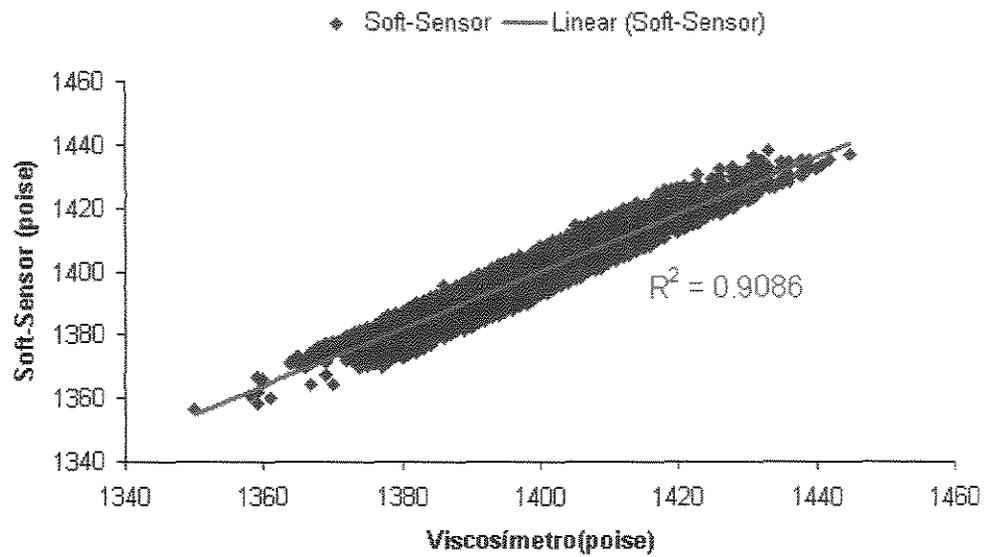


Figura 6.3 – Gráfico de dispersão

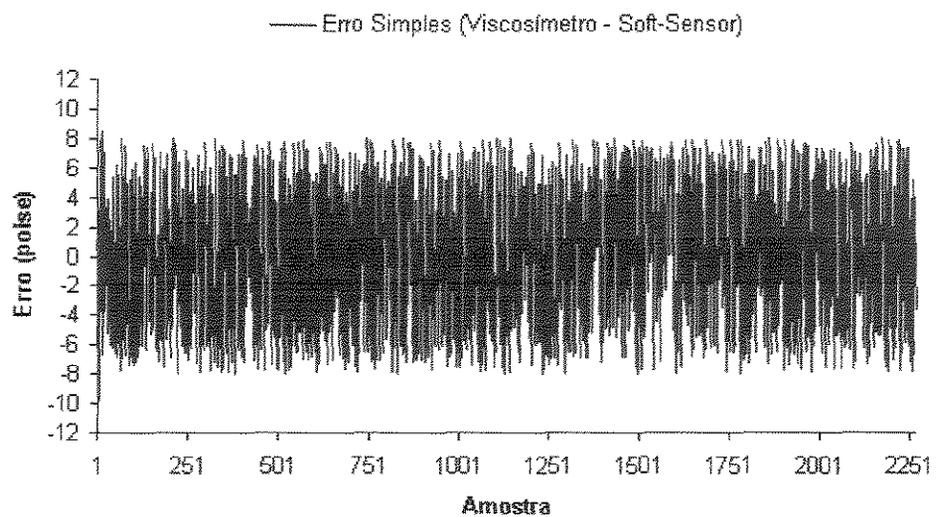


Figura 6.4 – Erro simples

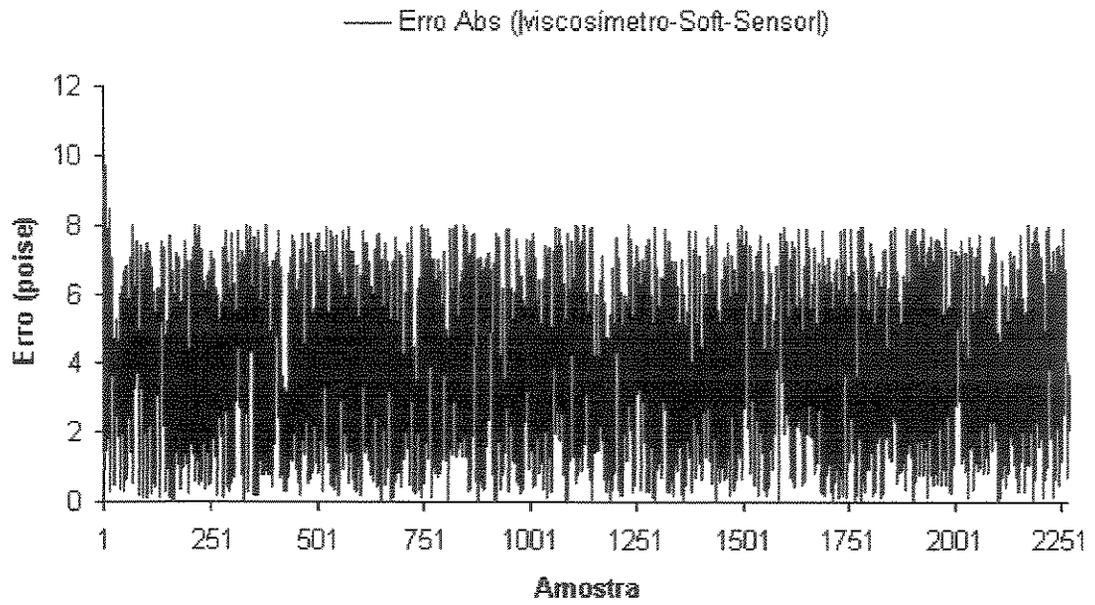


Figura 6.5 – Erro absoluto

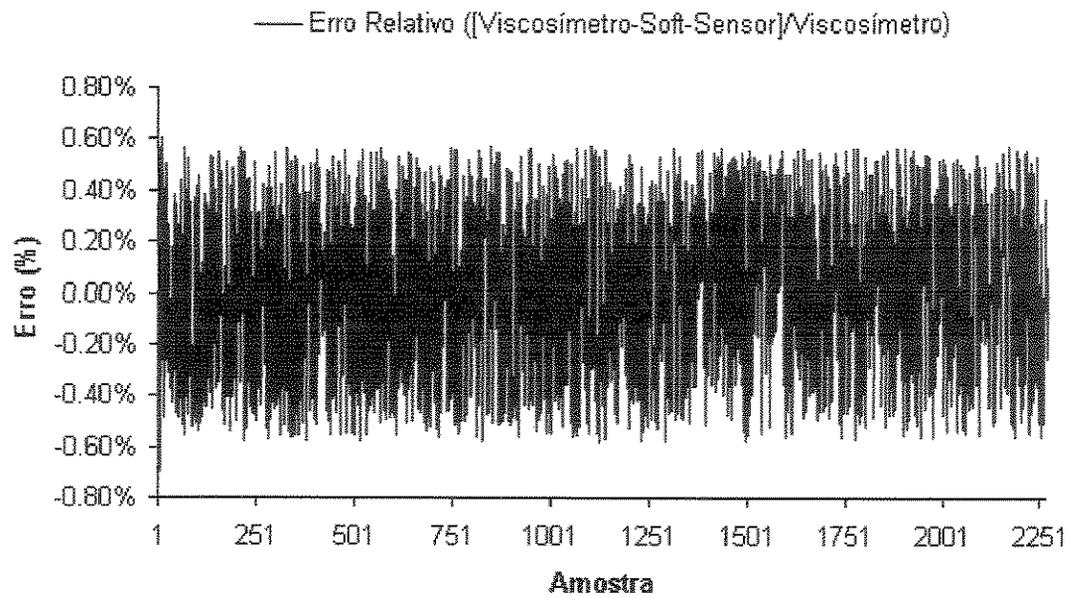


Figura 6.6 Erro relativo

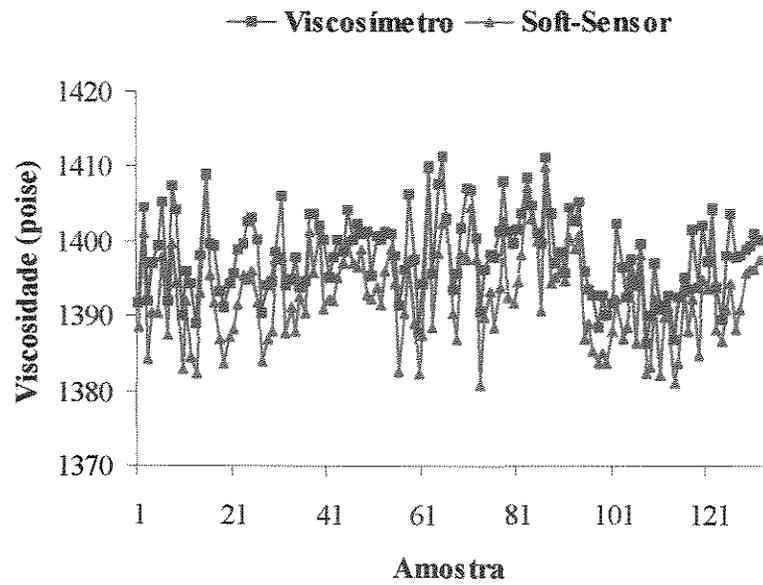


Figura 6.7 – Viscosímetro versus Soft-Sensor – Tempo Real

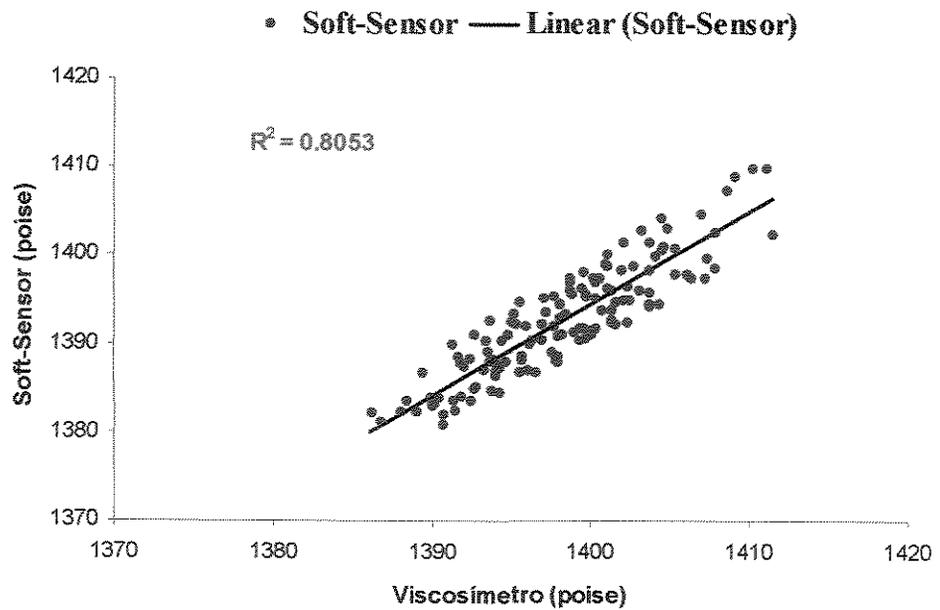


Figura 6.8 - Gráfico de dispersão – Tempo Real

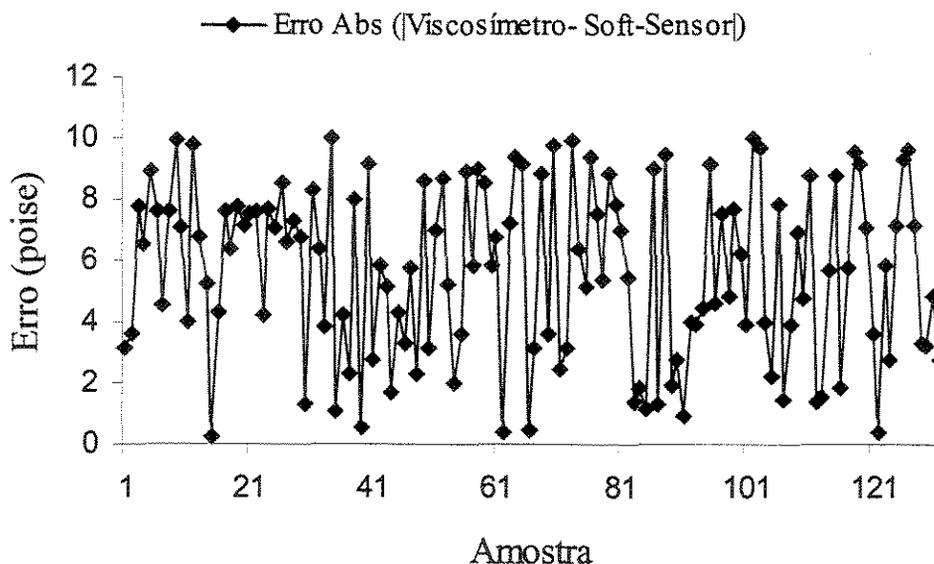


Figura 6.9 – Erro Absoluto - Medida Tempo Real

6.3 - Implementação do *Soft-Sensor* para controlar a planta

Após um período aproximado de três meses funcionando adequadamente, os viscosímetros de duas áreas do processo apresentaram alguns problemas e após algumas tentativas de recuperação sem sucesso, a equipe de produção passou a controlar a viscosidade usando corrente elétrica do motor do agitador, como ocorria usualmente antes.

Tendo em vista esta situação e a necessidade de um controle mais eficiente, surgiu a proposta de inserir *Soft-Sensor* no controle. Evidentemente, devido a grande importância desta etapa de controle, que garante a qualidade desejada do produto, bem como a larga produção (mais de seis toneladas por hora), algumas medidas de segurança foram asseguradas:

1. Criar uma lógica no CLP que verifica se as variáveis do processo estão dentro dos limites de especificação do processo e conseqüentemente dentro dos limites que foram treinadas.

2. Averiguar através de uma lógica no CLP se variáveis de processo estão dentro dos limites de especificação do processo e, por conseguinte, dentro dos limites adotados no treinamento da rede. Através disso, pode-se garantir um desempenho adequado da rede pois considera-se valores apenas dentro da faixa operacional de treinamento.
3. Quando o *Soft-Sensor* está controlando a viscosidade, o controlador que usa a corrente elétrica do motor do agitador fica no modo manual (malha aberta), sendo que a sua saída é atualizada simultaneamente com a saída do controlador do *Soft-Sensor*, sendo esta ajustada em modo automático (malha fechada). Uma vez que alguma variável extrapolar a faixa de segurança, a lógica deve contemplar automaticamente uma alteração do controle, chaveando a corrente do agitador para controle da planta, passando assim, o controlador para o modo automático, possibilitando o controle supervisão e regulatório de acordo com as especificações do processo. Como as saídas dos controladores estavam devidamente sincronizadas, não há necessidade de nenhuma ação brusca sobre o controle. Todas as vezes que ocorrer uma alteração do sistema de controle, um alarme sinaliza ao operador que o sistema de controle foi alterado e que alguma variável de processo está com uma variação anormal.

Existindo a possibilidade de controle da planta através do *Soft-Sensor*, foi implementada uma lógica com a opção de controle pelo viscosímetro ou *Soft-Sensor*. Vale ressaltar que a atuação do controlador usando o *Soft-Sensor* pode-se realizar tanto no caso de falha do viscosímetro como no caso da existência de uma diferença de 50 poise da viscosidade, é o maior valor esperado para o erro em função ao treinamento da rede em relação ao *Soft-Sensor* para um período de aproximadamente um dia. A figura 6.9, apresenta um fluxograma destas operações alternativas de controle:

Outro aspecto importante é a utilização de um mesmo controlador da viscosidade tanto pelo viscosímetro como pelo *Soft-Sensor*, alternando apenas a fonte da variável controlada do processo (PV). Se a opção for pela utilização do viscosímetro, o valor deste é transferido para a PV e o *Soft_Sensor* funciona apenas como indicação do valor da viscosidade. No caso da outra opção o funcionamento é o contrário. Os valores de sintonia do PID foram sintonizados igualmente para as duas configurações.

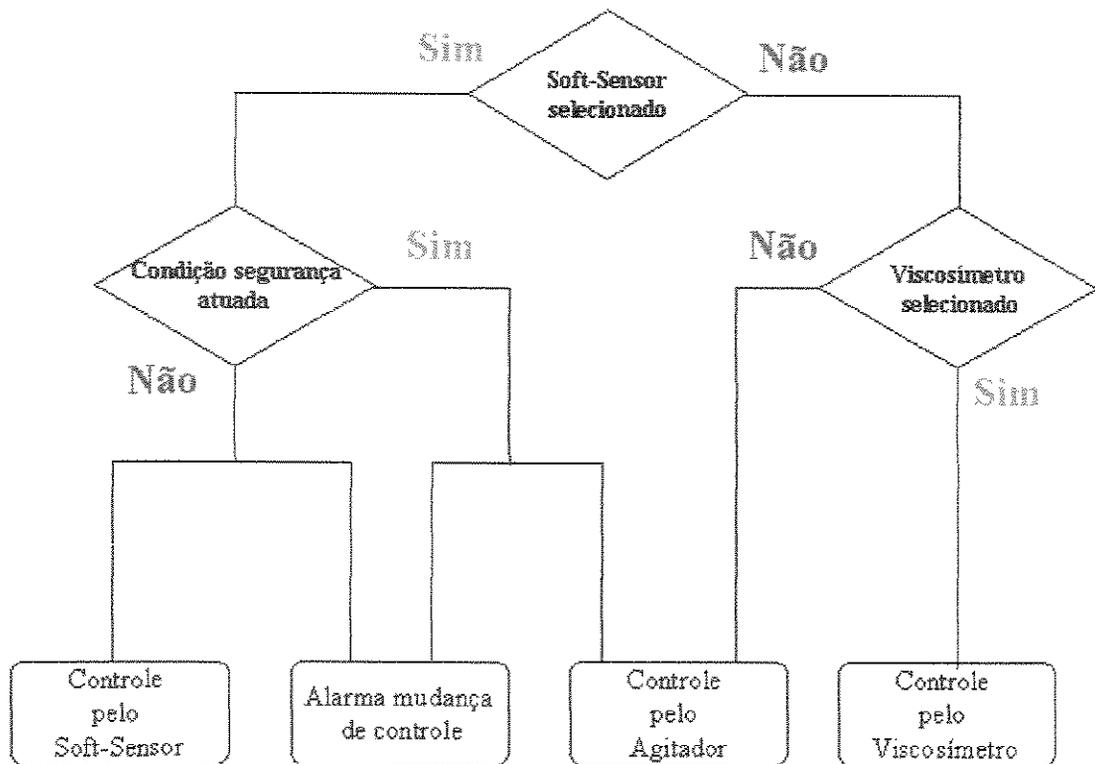


Figura 6.10 - Fluxograma da lógica implementada para utilização do Soft-Sensor.

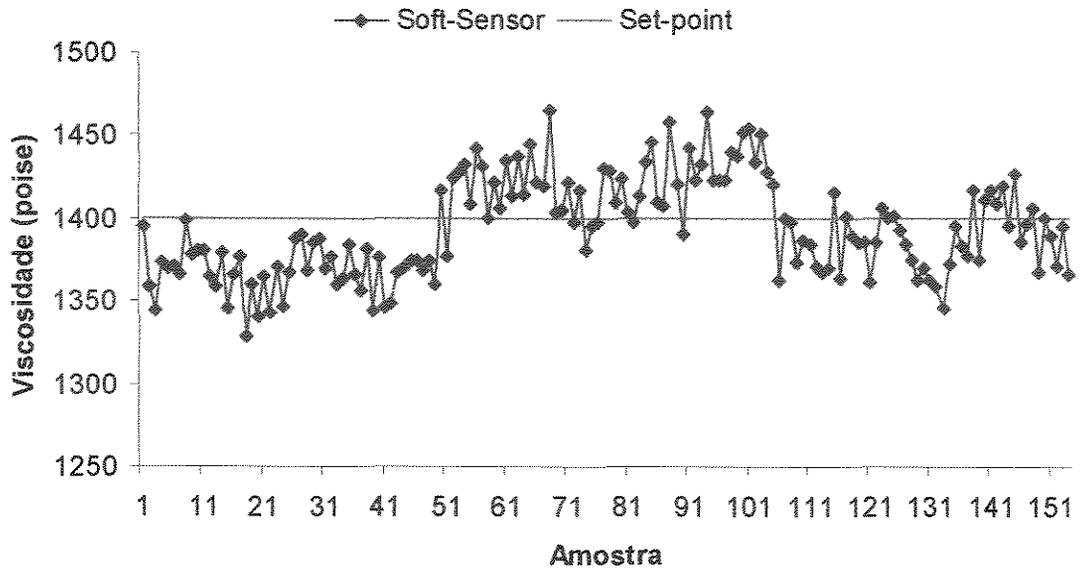


Figura 6.11 - Linha de Produção Controlada Pelo Soft-Sensor

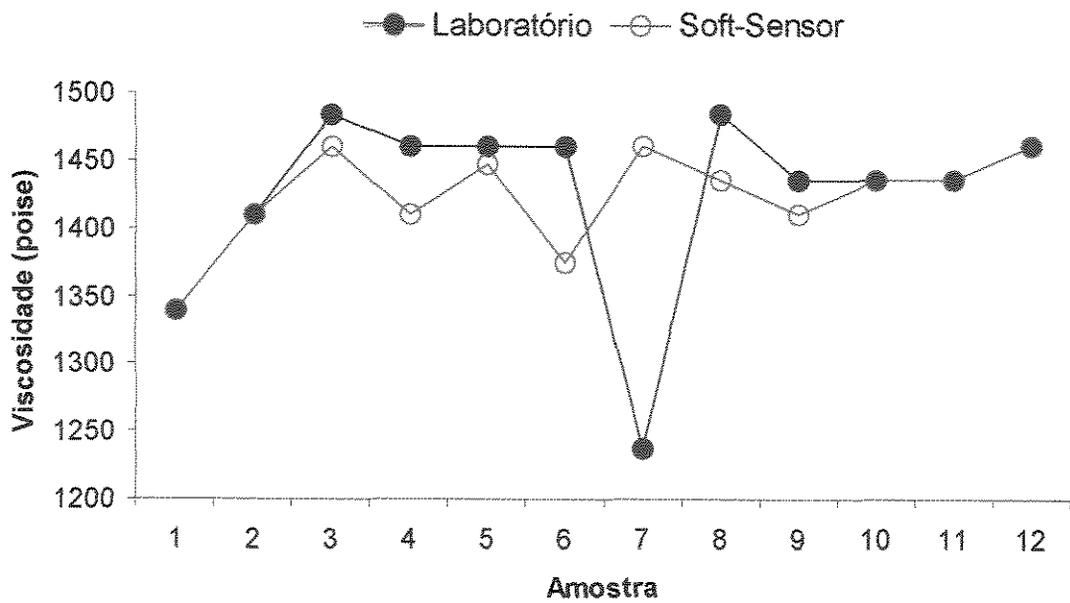


Figura 6.12 - Laboratório versus Soft-Sensor

As figuras 6.11 e 6.12 mostram que o controlador baseado no *Soft-Sensor* foi capaz de controlar adequadamente o processo. Pode-se notar que houve um dado de laboratório discrepante de outros valores, que pode ser um problema de amostragem já que os outros valores estão bem próximos ou exatamente iguais aos valores do *Soft-Sensor*.

As análises de laboratório foram necessárias pelo fato do viscosímetro extrapolar a faixa de operação e assim não ser possível comparar com valores em tempo real; isto permitiria uma segurança maior nos testes, pois cada valor do *Soft-Sensor* estaria sendo validado *on-line*.

6.4 Conclusões

Neste presente capítulo, foram apresentados os resultados obtidos do *Soft-Sensor* desenvolvido baseado na metodologia de redes neurais de operação *on-line* com o processo. Os resultados foram muito bons e no capítulo 8 algumas conclusões bem como os trabalhos futuros são apresentados.

CAPÍTULO 7

SISTEMA DE CONTROLE

Uma etapa importante desta dissertação foi a inclusão do *soft-sensor* no sistema de controle. Por isso, este capítulo tem como intuito descrever sucintamente o controle PID, que é largamente empregado nos controles da fábrica, bem como explicitar a metodologia de sintonia de controladores.

7.1 - Controlador Proporcional-Integrativo-Derivativo

Os controladores PID são essencialmente compostos por três modos de controle de realimentação de efeito proporcional, integral e derivativo. O modo proporcional tem o objetivo de reduzir o erro estacionário e tempo de resposta. No entanto, apesar da redução do erro estacionário, o modo proporcional não reduz absolutamente tal erro. Para tanto, existe o modo integrativo que elimina o erro estacionário, apesar de apresentar o inconveniente de aumentar a oscilação da resposta. O modo derivativo pode diminuir oscilação e tempo de resposta, propiciando melhor qualidade no tocante à estabilidade relativa do sistema. Um problema relacionado a este modo são ruídos presentes nas medições da variável controlada; este inconveniente pode resultar ações abruptas sobre a variável manipulada. A equação do controlador PID ideal é formada pela soma dos três modos é:

$$u(t) = \bar{u} + K_C \left[e(t) + \frac{1}{\tau_I} \int_0^t e(t) dt + \tau_D \frac{de}{dt} \right]$$

sendo $u(t)$ o valor da variável manipulada instantâneo, \bar{u} o valor da variável manipulada estacionário, $e(t)$ o erro estacionário entre a variável controlada e o valor desejado, K_C , τ_I e τ_D os parâmetros relativos aos modos proporcional, integral e derivativo.

Algoritmos de controle digital PID são necessários porque as aplicações de controle digital se processam de forma discreta; para tanto através das devidas transformações matemáticas, dois algoritmos de controle digital PID podem ser obtidos:

- algoritmo de posição

$$u(t) = \bar{u} + K_C \left[e_n + \frac{\Delta t}{\tau_I} \sum_{k=1}^n e_k + \frac{\tau_D}{\Delta t} (e_n - e_{n-1}) \right]$$

- algoritmo de velocidade

$$\Delta u(t) = K_C \left[(e_n - e_{n-1}) + \frac{\Delta t}{\tau_I} e_n + \frac{\tau_D}{\Delta t} (e_n - 2e_{n-1} + e_{n-2}) \right]$$

Um breve histórico referente aos controladores PID é mostrado na figura tabela 1:

Tabela 7.1 - Breve histórico de controladores PID

Período	
Década de 30	- disponibilidade dos controladores PID - primeiros artigos teóricos sobre controle de processos
Década de 40	- aplicações no meio industrial de controladores PID pneumáticos;
Década de 50	- aplicações no meio industrial de controladores PID eletrônicos
Fim da década de 50 e início da década de 60	- primeiras aplicações de controle por computador nas indústrias de processo
Décadas de 60 e 70	- revolução dos computadores digitais em controle de processos

7.2 - Metodologia de Sintonia de Controle PID

A partir de um modelo linear do processo a ser controlado, pode-se determinar o modelo do controlador (PID), baseando-se em métodos já bem sedimentados da literatura, tais como: método do lugar das raízes e projeto no domínio da frequência. O projeto do modelo do controlador pode ser igualmente traduzido como a determinação da sintonia

adequada do sistema de controle, ou seja, a sintonia que propicie um desempenho satisfatório e seguro do processo.

A metodologia de sintonia do controlador PID adotada nesta dissertação pode ser encontrada na íntegra em Torres & Pena (2002).

A sintonia de controle PID empregada por Torres & Pena (2002) pode ser sintetizada em dois passos fundamentais:

- 1) Identificação de um modelo na forma de uma função de transferência de 1ª ordem.
- 2) Determinação dos parâmetros do controlador PID através dos métodos de Yuwana e Seborg (1982), Seborg et. al. (1989), Gerry (1999), O'Dwyer (2000) bem como outros.

O modelo do processo é obtido através de uma mudança de *set-point*, após assegurada a condição de estabilização da planta. Pois sendo requisitado uma mudança de *set-point*, o controlador altera o valor da variável de entrada da planta; e a partir dos valores de saída e entrada da planta pode-se identificar a função de transferência de 1ª ordem representativa da planta, de acordo com o modelo da equação 1:

$$\frac{Y(s)}{U(s)} = \frac{Ke^{-\tau s}}{Ts + 1}$$

sendo K é o ganho do sistema, τ é atraso puro de tempo, T é a constante de tempo dominante, Y(s) representa a saída do sistema (PV) e U(s) a entrada da planta ou a saída do controlador (MV).

Cabe ressaltar que a identificação do modelo do processo é realizada em malha fechada não expondo a planta a riscos de uma operação em malha aberta. Uma forma bastante prática de determinação da função de transferência 1, através de testes em malha fechada, pode ser encontrada em Yuwana & Seborg (1982).

Após obtido o modelo do processo na forma da função de transferência de 1ª ordem, pode-se empregar uma série de métodos da literatura para determinação dos parâmetros do controlador PID ou PI (Yuwana e Seborg (1982), Seborg et. al. (1989), Gerry (1999), O'Dwyer (2000). A escolha do método de sintonia depende dos requisitos do sistema de controle, tais como tempo de resposta, *overshoot* e minimização do erro absoluto. Estes novos parâmetros (do PID ou PI) são transferidos automaticamente para o CLP que passa realizar o controle com os novos parâmetros com um desempenho significativamente superior aos parâmetros anteriores.

7.3 – Resultados

Conforme comentado no capítulo 4, a empresa possui um software (RSTune) de sintonia automática. Este software apresenta uma razoável simplicidade de uso, garantia de controle da malha sintonizada e possibilidade de intervenção direta em linha ao processo.

Apesar da sintonia em malha fechada apresentar maior vantagem no tocante à segurança do processo, pode-se realizar a sintonia de algumas malhas em malha aberta. Um exemplo disto, é o caso do controlador do vácuo do AP, que é um controlador escravo no controle da viscosidade. Neste caso de controle em cascata, o controlador escravo, tanto em malha fechada como aberta, apresenta o mesmo efeito sobre o controle da variável do controlador mestre.

A seguir será mostrado um ensaio realizado para sintonizar a malha de controle do vácuo do AP em malha aberta:

Ensaio:

Identificação da função de transferência do vácuo do Alto Polimerizador.

Metodologia:

Usar o software RStune para encontrar os valores da dinâmica do processo .

Procedimento:

- 1- Passar a malha de controle para manual (malha aberta).
- 2- Esperar o sistema estabilizar (ficar no estado estacionário, “nada muda com o tempo”)

- 3- Efetuar um degrau na saída do controlador de 77% para 84% , que é a faixa de trabalho da válvula de controle de vácuo, sem causar danos ao processo.
- 4- Esperar o sistema estabilizar novamente (passo-2).
- 5- Usar os dados coletados e realizar a análise.

A Figura 7.1 mostra o gráfico da mudança em degrau da saída do controlador do vácuo (CO), *Controller Output* - e a resposta dinâmica da variável de entrada do controlador (PV), *Process Variable*.

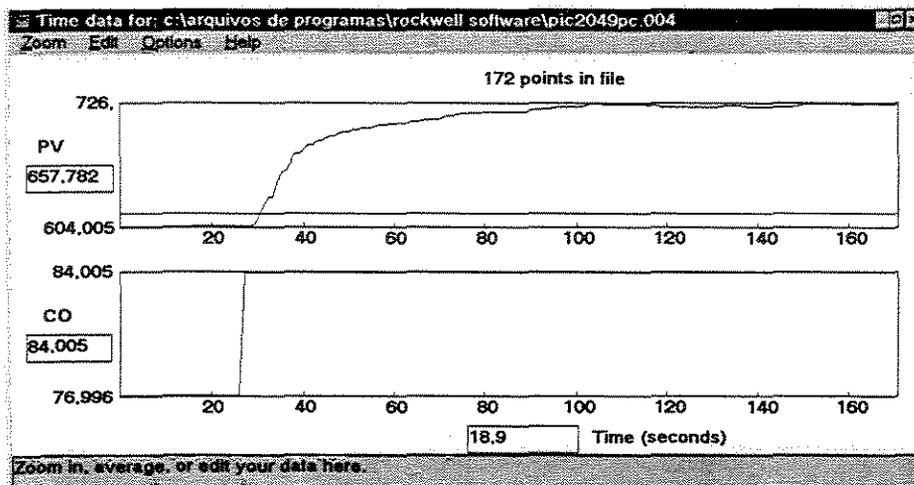


Figura 7.1 Degrau de 7% na saída da válvula de controle de vácuo em malha aberta.

A Figura 7.2 apresenta a função de transferência no domínio de Laplace obtida através do software Rstune.

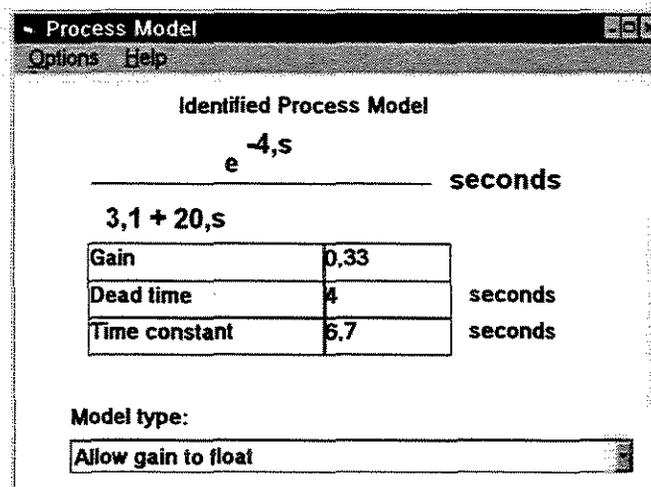


Figura 7.2 Função de transferência do vácuo do Alto Polimerizador.

Comentário :

Pode-se notar na Figura 7.1 que o sistema é de primeira ordem. Usando os dados da figura 7.2 e aplicando na equação :

$$G(s) = K_p \frac{e^{-Ds}}{\tau_p s + 1}$$

que representa mais de 80% dos sistemas de primeira ordem , obtém-se:

$$G(s) = 0,33 \frac{e^{-4s}}{6,7s + 1}$$

que pode ser simplificada para a seguinte equação:

$$G(s) = \frac{e^{-4s}}{20,3s + 3,1}$$

que é a equação encontrada pelo Rstune no domínio de Laplace.

A tabela 7.2 apresenta algumas regras praticas de sintonia de Ziegler-Nichols baseada na resposta do processo a uma excitação em degrau.

Tabela 7.2 - Regra de sintonia de Ziegler-Nichols para uma excitação em degrau

Tipo de Controlador	K_p	T_i	T_d
P	$\frac{T}{L}$	∞	0
PI	$0,9 \frac{T}{L}$	$\frac{L}{0,3}$	0
PID	$1,2 \frac{T}{L}$	$1L$	$0,5L$

Cálculo dos valores PID usando a Tabela 7.2, primeiro método de Ziegler-Nichols. No controle de vácuo geralmente são usadas válvulas de “igual porcentagem” e valores PI no controlador, portanto, pela Tabela 7.2 vem :

$L=4$ Seg (tempo morto);

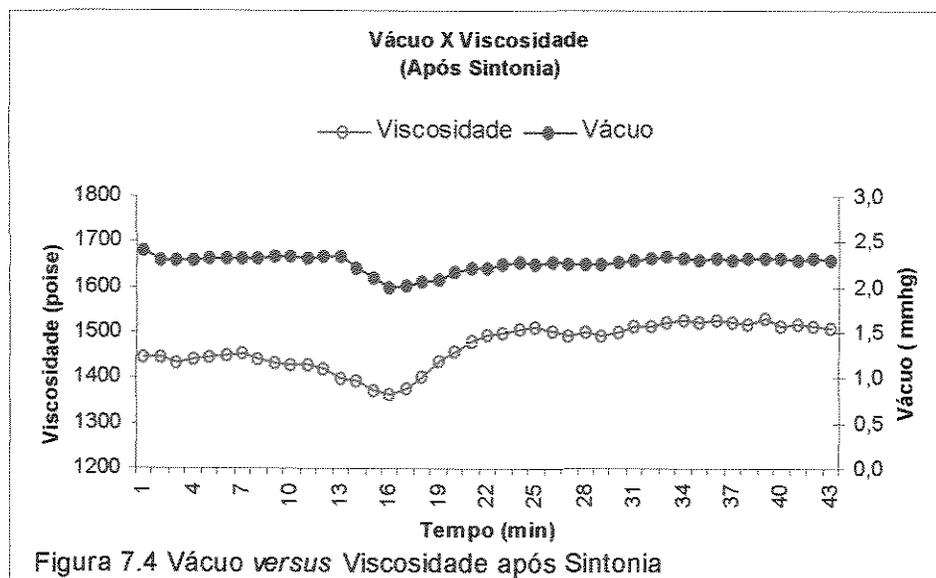
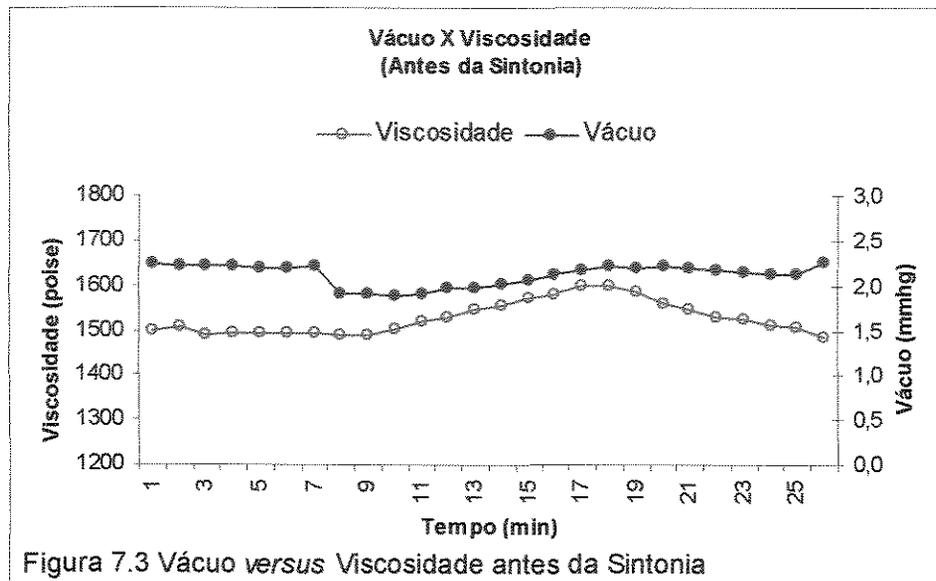
$T=6,7$ Seg (constante de tempo);

$P=0,9(T/L) \rightarrow P=1,5075$ valor proporcional para o controlador;

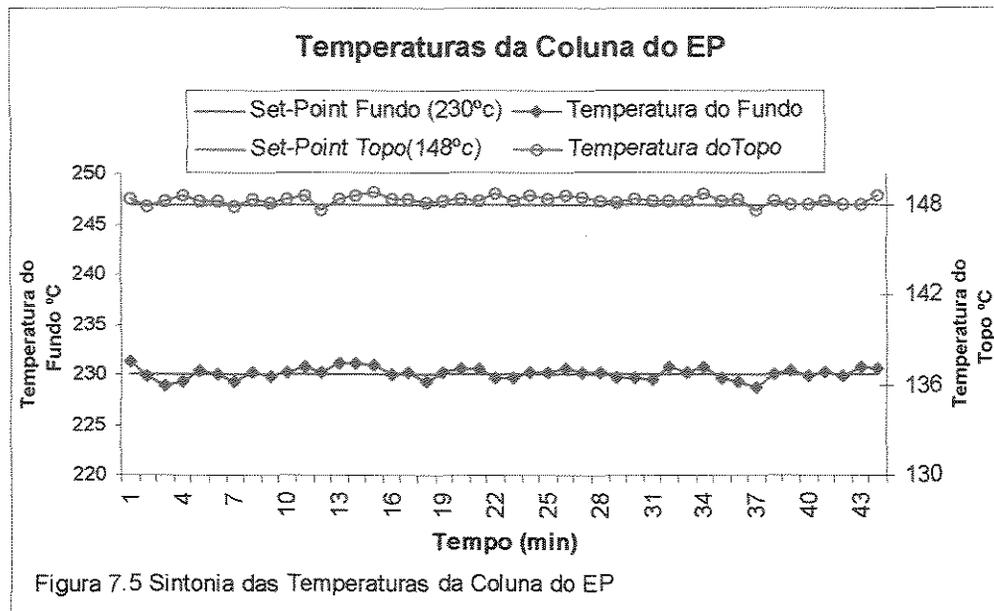
$I=L/0,3 \rightarrow I= 13,333$ valor integral para o controlador.

Estes parâmetros determinados pelo software são descarregados automaticamente para o PLC. Além da função de transferência, o software mostra vários gráficos para análise e simulação.

A Figura 7.3 mostra a variação do vácuo *versus* viscosidade antes da sintonia e a Figura 7.4 mostra a mesma variação após sintonia. Como se pode observar, a mudança é razoável e mostra que após a sintonia o sistema apresentou maior estabilidade, reduzindo significativamente a variabilidade.



Um dos controles de maior complexidade numa planta de produção de PET é o controle de temperaturas das colunas de destilação. A Figura 7.5 mostra o controle das duas temperaturas da coluna do EP e como este controle está robusto garantindo um funcionamento perfeito da coluna e um equilíbrio ideal para o processo, pois as variações nas temperaturas da coluna podem influenciar significativamente na eficiência do EP.



Dados de Controladores PID

Desborough et al. (2001) destacam que apenas 1/3 das malhas de controle está funcionando adequadamente, 1/3 encontra-se em modo manual e 1/3 piora o desempenho do processo ao invés de melhorá-lo. A Figura 7.6 mostra a situação dos controladores da empresa quanto ao modo de operação e que segundo a declaração anterior, está com um sistema de controle acima da média no que se refere a controladores trabalhando em modo manual.

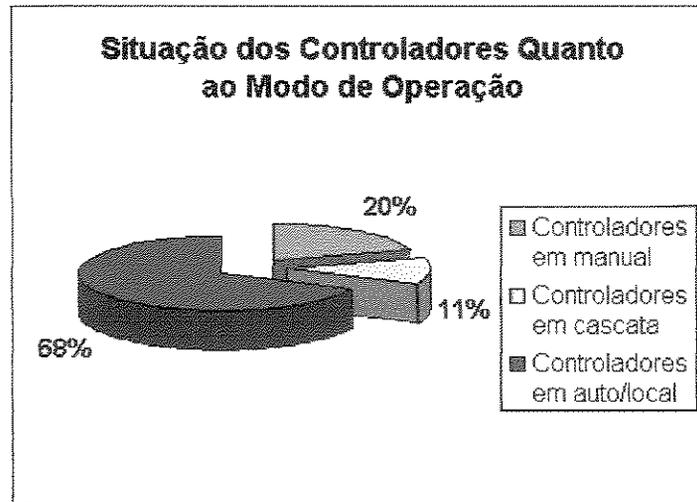


Figura 7.6 Situação dos controladores quanto ao modo de operação

A Figura 7.7 mostra a situação dos controladores quanto ao valor de saída, que indica, também, uma boa porcentagem em relação ao que foi citado acima.

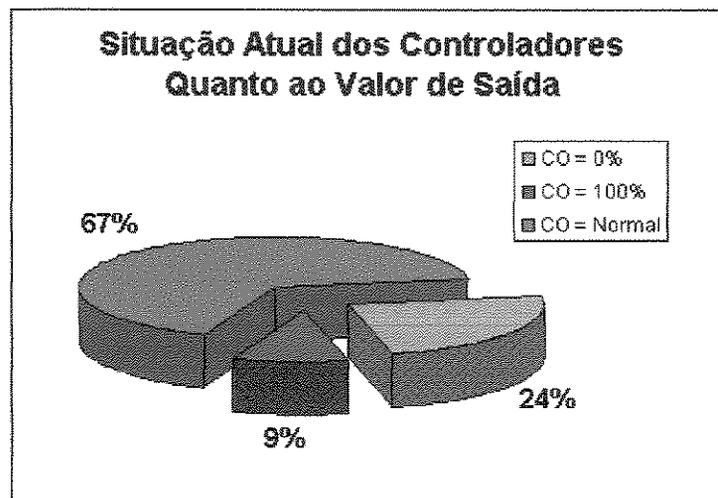


Figura 7.7 Situação dos controladores instalados na empresa, quanto ao valor de saída

Luyben (1990) afirma que, entre os controladores de efeitos proporcional, integrativo e derivativo, provavelmente 60% são PI (proporcional-integral), 20% são PID (proporcional-integral-derivativo) e 20% são P (proporcional) somente.

Considerando que as malhas de temperaturas são as que costumam utilizar controladores tipo PID e que as demais, na empresa, são PI, a Figura 7.8 mostra que os dados citados acima estão de acordo com o que está instalado na empresa, com exceção ao que se refere aos controladores P, que não são utilizados na empresa.

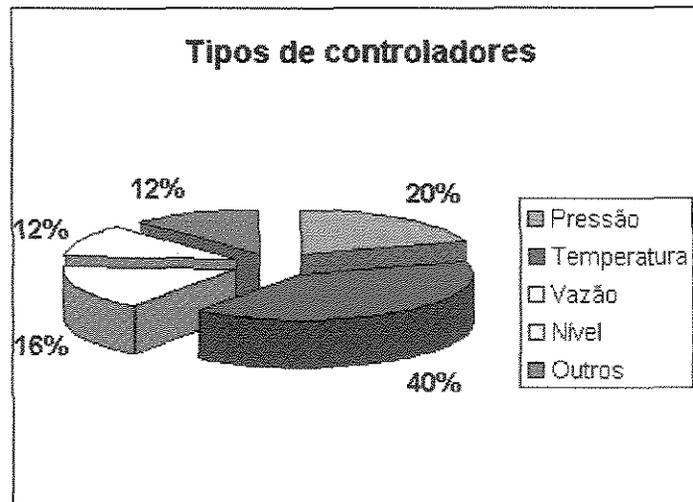


Figura 7.8 Tipos de controladores utilizados na empresa

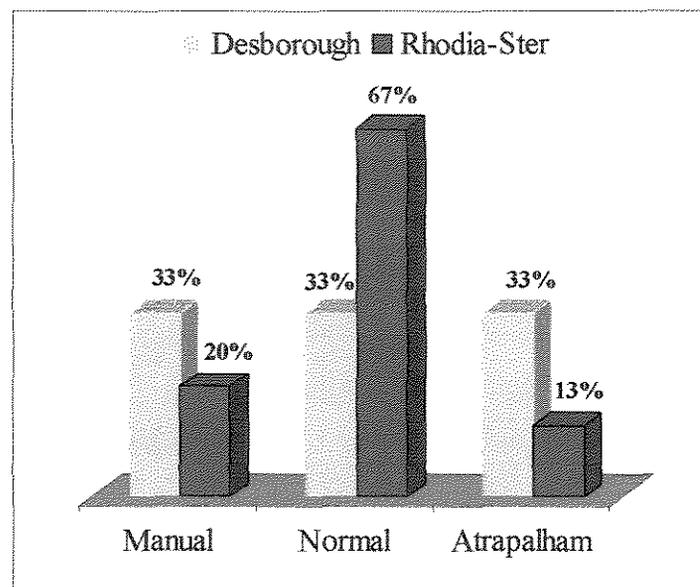


Figura 7.9 Funcionamento dos controladores.

7.4 – Conclusões

Neste capítulo foram apresentadas algumas definições básicas de controle PID e mostrado alguns resultados obtidos com o software de sintonia automática. Foi mostrado ainda que, apesar da literatura sugerir uma sintonia em malha fechada em função de não provocar grandes distúrbios ao processo, a sintonia feita em malha aberta quando o controle em cascata, pode ser empregada no controlador escravo, sem causar danos ao processo e obtendo excelentes resultados.

Finalizando, o processo de controle da Rhodia-Ster está acima do esperado em relação ao que foi exposto neste capítulo (Figura 7.9).

CAPÍTULO 8

CONCLUSÕES GERAIS & TRABALHOS FUTUROS

1. A implementação de redes neurais para validar medidas de sensores físicos que estão instalados na planta é uma alternativa em expansão e traz excelentes resultados para as indústrias.
2. Apesar do custo inicial para implementação e configuração da interligação dos programas para trabalhar *on-line*, torna-se viável economicamente a implantação de redes neurais, cuja implementação não tem um custo elevado, principalmente quando comparado ao custo de um viscosímetro, que além de ser um equipamento de alto custo, apresenta outros gastos como de manutenção ou perdas de produção.
3. A parte do trabalho no tocante ao treinamento da rede neural foi sem dúvida a mais exaustiva e prolongada. Embora já conhecidas as variáveis de processo que comporiam a rede e suas correlações, um trabalho criterioso foi realizado sobre a base de dados. Um dos fatores que mais influenciou para compor a base de dados foi o tempo de aquisição. Muitas amostras foram realizadas com tempos diferentes de aquisição até obter-se o valor ideal, no qual foi realizado todo o trabalho.
4. A utilização de um sensor virtual como variável de processo para os controladores é uma opção que possibilita um controle mais robusto e permite ainda que, no caso de ocorrência de um distúrbio no controle, possa-se identificar com facilidade qual ou quais as variáveis de processo que sensibilizaram tal variação. Esta conclusão foi constatada pela própria equipe de engenheiros do processo após o acompanhamento de um teste *on-line* com sensor virtual.

Os estudos realizados contemplaram uma aplicação de redes neurais que resultou, com grande sucesso, na implementação de sensores virtuais *on-line* com o processo. Os sensores obtidos para medição da viscosidade estão operando com grande aceitação.

Pode-se destacar os seguintes trabalho futuros:

1. Desenvolver modelos matemáticos híbridos com redes neurais, a fim de modelar os principais reatores e aplicar conceitos de controle avançado para otimizar o controle da planta.
2. Desenvolvimento de *Soft-Sensor* para medição de viscosidade no estado sólido.
3. Eliminação dos viscosímetros, através de sua substituição por *Soft-Sensors* em todas as linhas de processo.
4. Implementar um controlador multivariável sobre as variáveis de entrada do *Soft-Sensor*.
5. Desenvolver uma interface de visualização de variabilidade das variáveis de entrada do *Soft-Sensor*.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ackley, D.H., Hinton, G.E., and Sejnowski, T.J. (1985). A learning algorithm for Boltzmann machines. *Cognitive Science*. 9:147-169.
- Aleksander, I. (1966). Self-adaptive universal logic circuits. *Electronics Letters*. 2:321-322.
- Aleksander, I., Thomas, W.V., and Bowden, P.A. (1984). WISARD, a radical step forward in image recognition. *Sensor Review*. 4:120-124.
- Anderson, J.A. (1972). A simple neural network generating an interactive memory. *Mathematical Biosciences*. 14:197-220.
- Assis, A.J. and Maciel Filho, R. (2000) Soft Sensors Development for On-line Bioreactor State Estimation - *Computer and Chemical Engineering*, 24 pp. 1099-1103
- Astrom, K. J., Hagglund, T. (1988). *Automatic Tuning of PID Controllers*, Instrument Society of America, 2nd Edition.
- Baughman, D. R. and Liu, Y. A. (1995) *Neural Networks in Bioprocessing and Chemical Engineering*. Academic Press.
- Campello, R. J.G. B., Von Zuben, F. J., Amaral, W. C., Meleiro, L. A. C., & Maciel Filho, R. (2003). Hierarchical fuzzy models within the framework of orthonormal basis functions and their application to bioprocess control - *Chemical Engineering Science*, No. 58, pp 4259-4270.

- Carpenter, G. and Grossberg, S. (1987a). A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer vision, graphics and image processing*, 37:54-115.
- Carpenter, G. and Grossberg, S. (1987b). ART2: Self-organization of stable category recognition codes for analog input patterns. *Applied optics*, 26:4919-4930.
- Chan, W., Nascimento, C.A.O. (1994) Use of Neural Networks for Modeling of Oleofin Polymerization in High Tubular Reactors – *Journal of Applied Polymer Science*, Vol. 53, pp. 1277-1289
- D’Azzo, John J. e Houpis, Constantine H. (1978) *Análise e Projeto de Sistemas de Controle Lineares*, Rio de Janeiro, Guanabara Dois.
- Desborough, L., Nordh, P., Miller, R. (2001). Control System Reliability - Process Out of Control, *InTech with Industrial Computing*, August, págs. 52-55.
- Fukushima, K. (1975). Cognitron: a self-organizing multilayered neural network. *Biol. Cybernetics*. 20:121-136.
- Gerry, J. (1999). Tuning Process Controllers Starts in Manual, *InTech magazine*, May, págs. 125-126.
- Haykin. S. (1999) *Neural Networks - A comprehensive Foundation*. 2nd Edition. Prentice Hall.
- Hebb, D.O. (1949) *The organization of behaviour*. John Wiley and Sons.
- Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proc. Natl. Acad. Sci. USA*. 79:2554-2558.
- Kanerva, P. (1984). *Self-propagating search: a unified theory of memory*. PhD dissertation, University of Stanford.

- Kohonen, T. (1972). Correlation matrix memories. IEEE Transactions on Computers. 21:353-359.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. Biol. Cybernetics. 43:59-69.
- Ljung, L. (1997) System Identification. Theory for the User. Prentice-Hall Inc..
- Luyben, William L. (1989) Process modeling, simulation, and control for chemical engineers, McGraw – Hill.
- Martin, G. D. (1997)- Consider Soft Sensors - Chemical Engineering Progress, p.66-70, July.
- McCulloch, W.S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics. 5:115-133.
- Meleiro, L.A.C. and Maciel Filho, R. (2000) A Self-Tuning Adaptive Control Applied To Na Industrial Large Scale Ethanol Production - Computer and Chemical Engineering, 24 (2-7), pp. 925-930.
- Metal Leve Controles Eletrônicos Ltda (1989) Manual de Programação e Operação 1785-6.8.2
- Minsky M. (1956). Some universal elements for finite automata. In Shannon, C. and McCarthy, J. (Editors). Automata Studies (pp.117:128). Princeton, NJ: Princeton University Press.
- Minsky, M. and Papert, S. (1969) Perceptrons. Cambridge:MA: MIT Press.
- Mollenkamp, R.A.(1988) Controle Automático de Processos, São Paulo, EBRAS.

- Mujtaba, I. M. and Hussaim, M. A. (Editors). (2001) Application of Neural Networks and Other Learning Technologies in Process Engineering. Imperial College Press.
- Ng, G. W. (1997) Application of Neural Networks to Adaptive Control of Nonlinear Systems. Research Studies Press LTD. John Wiley & Sons INC.
- Nørgaard, M., Ravn, O., Poulsen, N. K., and Hansen, L.K. (2000) Neural Networks for Modelling and Control of Dynamic Systems. Springer-Verlag.
- O'Dwyer, A. (2000) A Summary of PI and PID Controller Tuning Rules for Processes with Time Delay. Part 2: PID Controller Tuning Rules, Preprints of PID'00 - IFAC Workshop on Digital Control - Past, Present and Future of PID Control, Terrassa, Spain, April.
- Ogata, Katsuhiko. (1978) Engenharia de Controle Moderno , Rio de Janeiro , Editora Prentice-Hall do Brasil.
- Pena, R. T., Jota, F. G., Torres, B. S., Aquino, R. D., Caldeira, F. R. (2001). Aplicações de um sistema de tanques com tecnologia Fieldbus em estudos de controle e instrumentação, Congresso Internacional de Automação, Sistemas e Instrumentação - ISA Show Brasil, São Paulo, Outubro.
- Quantrille, T. E. and Liu, Y. A. (1991) Artificial Intelligence in Chemical Engineering. Academic Press.
- Régnier, N., Defaye, G., Caralp, L. and Vidal, C.(1996) Software Sensor Based Control of Exothermic Batch Reactors - Chemical Engineering Science, Vol 51, No. 23, pp. 5125-5136.
- Rosenblatt, F. (1958). The perceptrons: a probabilistic model for information storage and organization in the brain. Psychological Review. 65:386-408.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986a). Learning internal representations by error propagation. In Rumelhart, D.E. and McClelland, J.L.

- (Editors). *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, MIT Press: Cambridge:MA.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1986b). Learning representations by back- propagation of errors. *Nature*. 323:533-536.
- Souza Jr., M. B. (1993) *Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos*. Tese de Doutorado, COPPE/PEQ/UFRJ, Rio de Janeiro.
- Teixeira Júnior, José Helvécio; Moura, José Antão Beltrão (1999). *Redes de computadores: serviços, administração e segurança*. São Paulo, Makron Books,
- Tham, M. T., Morris, A. J., Montague, G. A. (1989) Soft-Sensing: A solution to the Problem of Measurement Delays . *Chem. Eng. Res. Des.* 67, p. 547-554.
- Torres, B.S.; Pena, R.T. (2002) Estudo e Aplicação de um Software de Sintonia Automática de Controladores PID. *Intech*. No 46.
- Tremblay, David A.(1999) Using Simulation Technology to Improve Profitability In the Polymer Industry, Presented at AIChE Spring 1999 Meeting, Houston Texas- Aspen Technology Incorporated
- Von Neumann J. (1956). Probabilistic logics and the synthesis of reliable organisms from unreliable components. In Shannon, C. and McCarthy, J. (Editors). *Automata Studies* (pp.43:98). Princeton, NJ: Princeton University Press.
- Von Zuben, F. J. (1996) *Modelos Paramétricos e Não Paramétricos de Redes Neurais Artificiais e Aplicações*. Tese de Doutorado, Faculdade de Engenharia Elétrica, UNICAMP.
- Widrow, B. and Hoff, M.E. (1960). Adaptive switching circuits. *Proceedings of IRE WESCON Convention Record* (pp.96:104). New York: IRE Press.

- Willshaw, D.J., Buneman, O.P., and Longuet-Higgins, H.C. (1969). Non-Holographic Associative Memory. *Nature*. 222:960-962.
- Wilson, D.I., Agarwal, M. and Rippin, D.W.T. (1998) Experiences Implementing the Extend Kalman Filter on an Industrial Batch Reactor - *Computer and Chemical Engineering*, 22(11), pp. 1653-1672.
- Yuwana, M. and Seborg, D. E. (1982), A New Method for OnLine Controller Tuning, *AIChE Journal*, 28 - 3, 434 - 440.
- Zanin , Antônio Carlos ; Neto, Euclides Almeida e Moro, Lincoln F. Lautenschager. (1998) *Controle Avançado Aplicado à Indústria de Processo*, São Paulo, Apostila Petrobrás.
- Zill, Dennis G. e Cullen, Michael R. (2001) *Equações diferenciais*, São Paulo, Makron Books.
- Zingier, D., Araújo, O.Q.F., Coelho, M.A.Z. and Lima, E.L.(2001) Robust Soft Sensors for SBR Monitoring - *Water Science and Technology*, Vol. 43 No 3 pp.101-105.

APÊNDICE A

EQUAÇÕES PID DOS CONTROLADORES ALLEN-BRADLEY

A instrução PID usada pelo controlador CLP-5 da Allen-Bradley, permite selecionar os parâmetros de controle para proporcional, integral e/ou derivativo em qualquer combinação, e o tipo de equação de controle PID, utilizando parâmetros dependentes (ISA) ou independentes (AB).

Na equação AB, todas as três variáveis PID operam independentemente. Na equação ISA, uma alteração no parâmetro proporcional afeta os termos integral e derivativo. A tabela A.1 mostra as diferenças entre as duas equações.

Tabela A.1 - Diferenças entre as equações ISA e AB

Parâmetro	Padrão ISA (Ganho Dependente)	Padrão AB (Ganho Independente)
Proporcional	$K_c(E)$	$K_p(E)$
Integral	$\frac{K_c}{T_i} \int_0^t (E)dt$	$K_i \int_0^t (E)dt$
Derivativo	$K_c * T_d * \frac{d(E)}{dt}$	$K_d * \frac{d(E)}{dt}$

Equações AB

$$\text{Saída} = K_p(E) + K_i \int_0^t (E)dt + K_d * \frac{d(E)}{dt} + \text{BIAS} \quad (1)$$

ou

$$\text{Saída} = K_p(E) + K_i \int_0^t (E)dt + K_d * \frac{d(PV)}{dt} + \text{BIAS} \quad (2)$$

A equação (1) usa o parâmetro derivativo em função do erro e a equação (2) em função da PV. Onde:

Saída= % de fim de escala

K_p = Constante de ganho proporcional (sem unidade)

K_i = Constante de ganho integral (1/seg)

K_d = Constante de ganho derivativo (seg)

BIAS = Feedforward ou BIAS

E = Erro (em escala)

PV = Variável do processo (em escala)

SP = Referência

Equações ISA

$$\text{Saída} = K_c \left[(E) + \frac{1}{T_i} \int_0^t (E) dt + T_d * \frac{d(E)}{dt} \right] + \text{BIAS} \quad (3)$$

ou

$$\text{Saída} = K_c \left[(E) + \frac{1}{T_i} \int_0^t (E) dt + T_d * \frac{d(PV)}{dt} \right] + \text{BIAS} \quad (4)$$

A equação (3) usa o parâmetro derivativo em função do erro e a equação (4) em função da PV. Onde:

Saída= % de fim de escala

K_c = Constante de ganho proporcional (sem unidade)

$1/T_i$ = Constante de ganho de rearme (repetições por minuto)

T_d = Constante de ganho de velocidade (minutos)

BIAS = Feedforward ou BIAS

E = Erro (em escala)

PV = Variável do processo (em escala)

SP = Referência

A figura A.1 - mostra o diagrama de blocos de uma malha fechada.

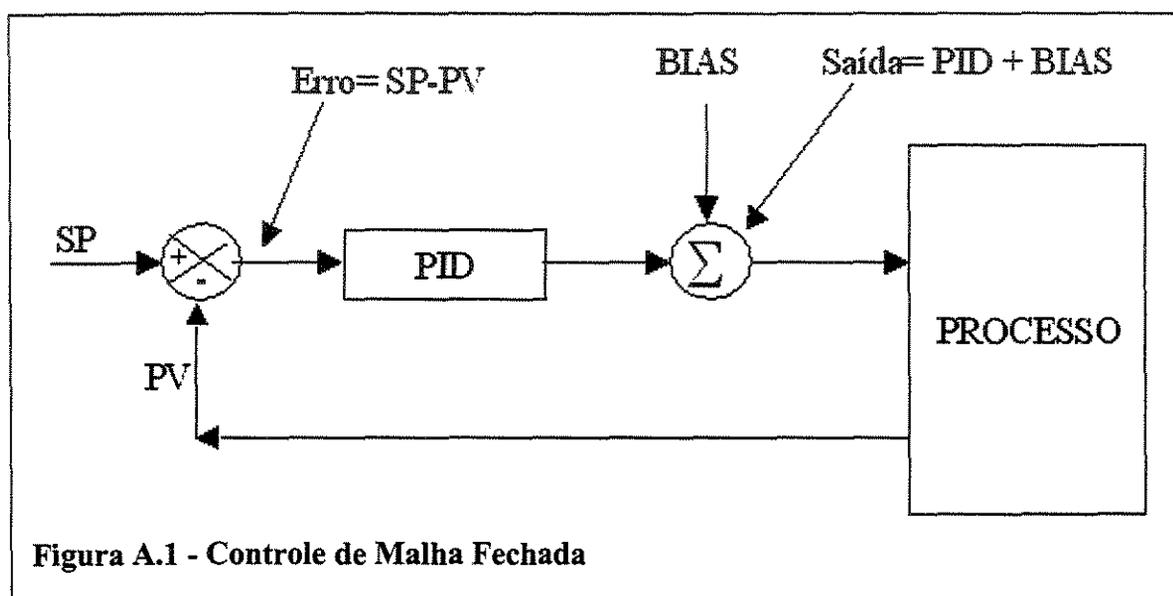


Figura A.1 - Controle de Malha Fechada