



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

PROGRAMA TECNOLOGIA DE PROCESSOS QUÍMICOS E
BIOQUÍMICOS

GUILHERME DE CASTRO SILVA

ESTUDO DE UM CONTROLADOR PREDITIVO NÃO LINEAR
MULTIVARIÁVEL BASEADO EM REDES NEURONAIAS

ORIENTADORES

PROF. MAURÍCIO BEZERRA DE SOUZA JÚNIOR, D.Sc.
PROF. ARGIMIRO RESENDE SECCHI, D.Sc.

FEVEREIRO 2014

ESTUDO DE UM CONTROLADOR PREDITIVO NÃO LINEAR
MULTIVARIÁVEL BASEADO EM REDES NEURONAIS

GUILHERME DE CASTRO SILVA

Dissertação de Mestrado
apresentada ao Programa de
Pós-Graduação em Tecnologia
de Processos Químicos e
Bioquímicos, para a obtenção
do título de Mestre em Ciências
(M.Sc.).

Silva, Guilherme de Castro.

Estudo de um controlador preditivo não linear multivariável baseado em redes neurais / Guilherme de Castro Silva. – 2014.

xx, 105 f.: il. ; 30 cm.

Dissertação (mestrado) – Universidade Federal do Rio de Janeiro, Escola de Química, Programa de Pós-Graduação em Tecnologia de Processos Químicos e Bioquímicos, Rio de Janeiro, ano.

Orientadores: Maurício Bezerra de Souza Junior e Argimiro Resende Secchi.

1. Controle de processos. 2. Controle preditivo. 3. Rede neurais. 4. Reator químico. I. Souza Jr., Maurício Bezerra de (Orient.). II. Secchi, Argimiro Resende (Orient.) III. Universidade Federal do Rio de Janeiro. Escola de Química. IV. Título.

GUILHERME DE CASTRO SILVA**ESTUDO DE UM CONTROLADOR PREDITIVO NÃO LINEAR
MULTIVARIÁVEL BASEADO EM REDES NEURONAIS**

Dissertação submetida ao Corpo Docente do Programa de Pós Graduação em Tecnologia de Processos Químicos e Bioquímicos da Escola de Química da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Ciência e Tecnologia de Processos Químicos e Bioquímicos.

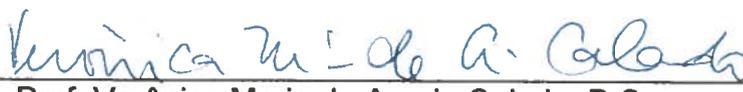
Aprovado por:



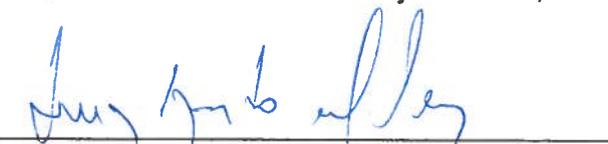
Prof. Mauricio Bezerra de Souza Júnior, D.Sc.
Orientador



Prof. Argimiro Resende Secchi, D.Sc.
Orientador



Prof. Verônica Maria de Araujo Calado, D.Sc.



Prof. Luiz Augusto da Cruz Meleiro, D.Sc.



Marcos Vinicius de Carvalho Gomes, D.Sc.

RIO DE JANEIRO, RJ - BRASIL
FEVEREIRO DE 2014

Aos meus pais, Clóvis e Márcia,
e à minha noiva, Ananda,
com todo meu amor.

AGRADECIMENTOS

Primeiramente à Deus, pela saúde e tranquilidade para que pudesse chegar até aqui.

Aos meus pais, Clóvis e Márcia, que sempre me apoiaram, mesmo que as vezes de tão longe.

À mulher da minha vida, Ananda, pelo incentivo, apoio, companheirismo e amor, e por, nos momentos mais difíceis, ter sempre acreditado em mim.

Aos professores Maurício e Argimiro, pela orientação e dedicação em todas etapas deste trabalho.

Aos meus amigos pelo apoio e momentos de descontração.

E a todos aqueles que contribuíram para minha formação acadêmica.

*“A mente que se abre a uma nova ideia jamais retorna ao seu tamanho original.”
Albert Einstein*

RESUMO

SILVA, Guilherme de Castro. Estudo de um Controlador Preditivo Não Linear Multivariável Baseado em Redes Neurais. Orientadores: Maurício Bezerra de Souza Júnior e Argimiro Resende Secchi. Rio de Janeiro: EQ/UFRJ, 2014. Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos).

Os controladores preditivos não lineares surgiram para tentar superar seus correspondentes lineares, quando estes não apresentam desempenho satisfatório em toda faixa operacional. Dentre os modelos não lineares, as redes neurais se destacam por sua flexibilidade e capacidade de predição. Nesta dissertação, avaliou-se o desempenho de um controlador preditivo não linear multivariável baseado em redes neurais, utilizando como objeto de estudo o reator CSTR com cinética de Van de Vusse. Para investigar problemas inerentes ao modelo interno do controlador, foi projetado um controlador com predições dadas pelo próprio modelo do processo (modelo perfeito). Observou-se que a utilização de redes individuais para cada variável controlada melhora a capacidade de predição. Foi avaliada a influência dos principais parâmetros dos controladores, com destaque para o tempo de amostragem, que se mostrou importante para a estabilidade dos controladores. Os controladores baseados em redes neurais apresentaram bom desempenho em regiões com mudança de sinal do ganho, sendo capazes de manter o processo estável em diversos cenários, mas apresentando pequenos *offsets* em alguns casos. Apesar de apresentar melhor desempenho, o controlador baseado na predição com o modelo perfeito mostrou-se lento, chegando a requerer tempos de cômputo superiores ao tempo de amostragem utilizado.

ABSTRACT

SILVA, Guilherme de Castro. Study of a Multivariable Nonlinear Predictive Controller based on Neural Networks. Supervisors: Maurício Bezerra de Souza Júnior and Argimiro Resende Secchi. Rio de Janeiro: EQ/UFRJ, 2014. M.Sc. Dissertation (Graduate Program on Technology of Chemical and Biochemical Processes).

Nonlinear predictive controllers have emerged to fill the gap of nonlinear systems, where linear models did not show good performance in all operating ranges. Neural networks models stand up as an important tool for predictions of nonlinear system, due to their flexibility and prediction ability. The aim of this dissertation was to evaluate the performance of a nonlinear multivariable predictive controller based on neural networks. The benchmark CSTR reactor with Van de Vusse kinetics was used as a study object. A controller based on predictions given by the actual process model (perfect model) was designed to characterize problems inherent to the internal model. It was observed that the use of individual networks for each controlled variable improves the prediction model. The influence of the main parameters of the controllers was evaluated. The sampling time was shown important for the stability of the controllers. The controllers based on neural networks were able to keep the process stable in different scenarios, including sign change of the process gain, although short offsets were noted in some cases. Despite presenting better performance, the controller based on the perfect model proved to be slow with computation times higher than the sampling time in some cases.

CONTEÚDO

1	INTRODUÇÃO.....	1
1.1	Motivação	1
1.2	Objetivo.....	2
1.3	Organização do Trabalho	3
2	CONTROLE PREDITIVO	4
2.1	Introdução.....	4
2.2	Breve Histórico	7
2.3	Controle Preditivo Linear	8
2.3.1	Controle por Matriz Dinâmica (DMC).....	10
2.3.2	Controle Preditivo Generalizado (GPC).....	13
2.3.3	Modelo em Espaço de Estados	16
2.4	Controle Preditivo Não Linear	19
2.4.1	Redes Neurais	22
3	MODELO DO PROCESSO	33
3.1	Descrição e Modelagem.....	33
3.2	Comportamento do Processo.....	35
3.3	Seleção da Região de Estudo	38
3.4	Linearização do Modelo	39
3.5	Aplicações de Controle ao Modelo na Literatura.....	40
4	APLICAÇÃO DO CONTROLE PID MULTIMALHAS	44
4.1	Sintonia da Malha de Concentração de B	45
4.2	Sintonia da Malha de Temperatura do Reator	48
4.3	Método de <i>Detuning</i>	50
4.4	Resultados.....	51
5	IDENTIFICAÇÃO COM REDES NEURONAIS.....	55
5.1	Geração de Dados para Treinamento	55
5.2	Treinamento das Redes Neurais.....	56
5.3	Avaliação da Capacidade de Predição das Redes	61
6	APLICAÇÃO DO CONTROLE PREDITIVO NÃO LINEAR	71
6.1	Predição por Redes Neurais	74
6.2	Predição pelas Equações Diferenciais	79
6.3	Avaliação da Influência dos Parâmetros	83

6.3.1	Pesos das Variáveis Controladas	84
6.3.2	Pesos das Variáveis Manipuladas	85
6.3.3	Horizontes de Predição e Controle	86
6.4	Comparação dos Resultados	88
7	CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS	97
7.1	Conclusões	97
7.2	Sugestões para Trabalhos Futuros	99
	REFERÊNCIAS BIBLIOGRÁFICAS	100

LISTA DE FIGURAS

Figura 1 – Evolução das publicações relacionadas aos termos <i>Predictive Control</i> e <i>Nonlinear (Non-linear) Predictive Control</i> .	1
Figura 2 – Estrutura básica do MPC.	6
Figura 3 – Representação esquemática do conceito básico do MPC.	7
Figura 4 – Arquitetura genérica de ANN (a) <i>Feedforward</i> (b) Recorrentes.	25
Figura 5 – Modelo de um neurônio artificial.	26
Figura 6 – Representação esquemática de uma rede do tipo radial (RBF).	28
Figura 7 – Modelo básico de controle direto.	30
Figura 8 – Modelo básico de controle indireto.	30
Figura 9 – Estrutura geral de um controlador preditivo baseado em redes neuronais.	31
Figura 10 – Exemplo de rede que recebe dados atrasados no tempo.	32
Figura 11 – Representação esquemática do reator de CSTR com reação de Van de Vusse.	33
Figura 12 – Concentração no estado estacionário de B em função da razão de alimentação.	36
Figura 13 – Temperatura do reator no estado estacionário em função da razão de alimentação.	36
Figura 14 – Concentração no estado estacionário de B em função da razão de alimentação para o modelo isotérmico.	37
Figura 15 – RGA do processo em função da razão de alimentação.	38
Figura 16 – Simulação da atuação do controlador LLT na mudança de <i>setpoint</i> no reator de Van de Vusse. (a) Resposta na saída do sistema (b) respectivas ações de controle tomadas.	41
Figura 17 – Dados de teste da rede atuando como simulador.	42
Figura 18 – Estrutura do controlador utilizado por ANURADHA <i>et al.</i> (2009).	43
Figura 19 – Modelo com controle PID no Simulink®.	44
Figura 20 – Análise do lugar das raízes da função de transferência $G_1(s)$.	45
Figura 21 – Resposta em malha aberta para degrau de -20% em Fin no instante $t=0,02$ h.	46
Figura 22 – Mudança de <i>setpoint</i> (-0,1 mol/l) – Sintonia malha de concentração de B.	47
Figura 23 – Análise do lugar das raízes da função de transferência $G_4(s)$.	48
Figura 24 – Resposta em malha aberta para degrau de 10% em Q_k no instante $t=0,02$ h.	48

Figura 25 – Mudança de setpoint (+1K) – Sintonia malha de temperatura.	50
Figura 26 – Mudança de <i>setpoint</i> (-0,1 mol/l) – Malha de C_B	52
Figura 27 – Mudança de <i>setpoint</i> (-0,1 mol/l) – Malha de T	52
Figura 28 – Perturbação na concentração de A na alimentação (+10%) – Malha de C_B	53
Figura 29 – Perturbação na concentração de A na alimentação (+10%) – Malha de T	53
Figura 30 – Mudança de <i>setpoint</i> (+0,1 mol/l) – Malha de C_B	54
Figura 31 – Mudança de <i>setpoint</i> (+0,1 mol/l) – Malha de T	54
Figura 32 – Mapa de pontos simulados (tempo de amostragem de 0,002h).	56
Figura 33 – Estrutura básica das redes neuronais.	57
Figura 34 – Dados preditos versus dados reais para tempo de amostragem de 0,002h	59
Figura 35 – Dados preditos versus dados reais para tempo de amostragem de 0,004h	60
Figura 36 – Dados preditos versus dados reais para tempo de amostragem de 0,008h	60
Figura 37 – Perturbações aplicadas a vazão de alimentação.....	61
Figura 38 – Simulação redes MLP com tempo de amostragem de 0,002h.....	61
Figura 39 – Simulação redes lineares com tempo de amostragem de 0,002h.....	62
Figura 40 – Simulação redes MLP com tempo de amostragem de 0,004h.....	62
Figura 41 – Simulação redes lineares com tempo de amostragem de 0,004h.....	63
Figura 42 – Simulação redes MLP com tempo de amostragem de 0,008h.....	63
Figura 43 – Simulação redes lineares com tempo de amostragem de 0,008h.....	64
Figura 44 – Simulação redes MLP individuais com tempo de amostragem de 0,002h.	66
Figura 45 – Simulação redes MLP individuais com tempo de amostragem de 0,004h.	67
Figura 46 – Simulação redes MLP individuais com tempo de amostragem de 0,008h.	67
Figura 47 – Comportamento estacionário do processo considerando as redes com tempo de amostragem de 0,002h.....	69
Figura 48 – Comportamento estacionário do processo considerando as redes com tempo de amostragem de 0,004h.....	69
Figura 49 – Comportamento estacionário do processo considerando as redes com tempo de amostragem de 0,008h.....	69

Figura 50 – Estrutura dos controladores NMPC empregados.	71
Figura 51 – NMPC com redes MLP únicas – Cenário de redução de SP de C_B	75
Figura 52 – NMPC com redes MLP únicas – Cenário de aumento de SP de C_B	76
Figura 53 – NMPC com redes MLP individuais – Cenário de redução de SP de C_B	77
Figura 54 – NMPC com redes MLP individuais – Cenário de aumento de SP de C_B	78
Figura 55 – NMPC com redes MLP individuais – Cenário de redução de SP de C_B	81
Figura 56 – NMPC com redes MLP individuais – Cenário de aumento de SP de C_B	82
Figura 57 – Avaliação da razão entre os pesos das variáveis controladas ($R_w = w_T/w_{C_B}$).	84
Figura 58 – Influência dos pesos das variáveis manipuladas ($\lambda_{F_{in}}$ e λ_{Q_k}).	85
Figura 59 – Influência do horizonte de predição (P).	86
Figura 60 – Influência do horizonte de controle (M).	87
Figura 61 – Redução de SP de C_B	89
Figura 62 – Aumento de SP de C_B	90
Figura 63 – Redução de SP de T	91
Figura 64 – Aumento de SP de T	92
Figura 65 – Perturbação positiva em C_{Ain}	93
Figura 66 – Perturbação negativa em C_{Ain}	95

LISTA DE TABELAS

Tabela 1 – Aplicações comerciais de MPC linear.	9
Tabela 2 – Funções de ativação normalmente utilizadas.....	27
Tabela 3 – Parâmetros cinéticos da reação.	34
Tabela 4 – Propriedades físico-químicas e dimensões do reator.....	34
Tabela 5 – Relação de variáveis controladas e manipuladas para cada controlador.	45
Tabela 6 – Parâmetros do controlador PID para malha de concentração de B.	47
Tabela 7 – Parâmetros do controlador PID para malha de temperatura.....	49
Tabela 8 – Parâmetros do controlador PID para malha de temperatura.....	51
Tabela 9 – Limites utilizados para as variáveis manipuladas.	51
Tabela 10 – Limites das variáveis utilizados para geração de padrões.	55
Tabela 11 – Redes obtidas para tempo de amostragem igual a 0,002h.	58
Tabela 12 – Redes obtidas para tempo de amostragem igual a 0,004h.	58
Tabela 13 – Redes obtidas para tempo de amostragem igual a 0,008h.	59
Tabela 14 – Comparação dos erros de cada tempo de amostragem, tipo de rede e quantidade de dados atrasados.	64
Tabela 15 – Redes individuais obtidas para tempo de amostragem igual a 0,002h.	65
Tabela 16 – Redes individuais obtidas para tempo de amostragem igual a 0,004h.	65
Tabela 17 – Redes individuais obtidas para tempo de amostragem igual a 0,008h.	66
Tabela 18 – Comparação dos erros de cada tempo de amostragem para as redes individuais.	68
Tabela 19 – Comparação dos resultados das redes únicas e individuais para cada tempo de amostragem.....	70
Tabela 20 – Cenários utilizados para comparação entre os diferentes controladores.	88
Tabela 21 – Parâmetros dos controladores preditivos utilizados.	88
Tabela 22 – ISE e SU - Redução de SP de C_B	89
Tabela 23 – ISE e SU - Aumento de SP de C_B	90
Tabela 24 – ISE e SU - Redução de SP de T	91
Tabela 25 – ISE e SU - Aumento de SP de T	92
Tabela 26 – ISE e SU - Perturbação positiva em C_{Ain}	94
Tabela 27 – ISE e SU - Perturbação negativa em C_{Ain}	95
Tabela 28 – Tempos de simulação.....	96

LISTA DE ABREVIATURAS

ANN	<i>Artificial neural network</i> ou rede neural artificial
CARIMA	<i>Controlled autoregressive integrated and moving average</i>
CSTR	<i>Continuous stirred tank reactor</i> ou reator contínuo do tipo tanque agitado
DMC	<i>Dynamic matrix control</i> ou controle por matriz dinâmica
EDO	Equação diferencial ordinária
GPC	<i>Generalized predictive control</i> ou controle preditivo generalizado
HIECON	<i>Hierarchical constraint control</i>
IDCOM	<i>Identification and command</i>
IMC	<i>Internal Model Control</i> ou modelo de controle interno
ISE	Somatório dos erros quadráticos
LLT	<i>Local linearization on the trajectory</i> ou linearização ao longo da trajetória
MIMO	<i>Multiple input – Multiple output</i> ou sistema composto de várias entradas – várias saídas
MLP	<i>Multilayer perceptron</i> ou rede neural do tipo perceptron de múltiplas camadas
MPC	<i>Model predictive control</i> ou controle preditivo baseado em modelo
NMPC	<i>Nonlinear model predictive control</i> ou controle preditivo baseado em modelo não linear
PID	<i>Proportional-integral-derivative control</i> ou controle proporcional-integral-derivativo
QDMC	<i>Quadratic dynamic matrix control</i> ou controle quadrático por matriz dinâmica
RBF	<i>Radial basis function</i> ou rede neural tipo função de base radial
RGA	Relative gain matrix ou matriz de ganhos relativos
SISO	<i>Single input – Single Output</i> ou sistema de uma entrada – uma saída
SMCA	<i>Setpoint multivariable control architecture</i>
SMOC	<i>Shell multivariable optimizing controller</i>
SP	<i>Setpoint</i> ou ponto de ajuste
SQP	<i>Successive quadratic programming</i> ou programação quadrática sucessiva

SU	Esforço de manipulação
SVN	<i>Support vector machines</i> ou máquinas de vetores de suporte
TDNN	<i>Time delay</i> neural network

LISTA DE VARIÁVEIS

Notação

\wedge	Subscrito indica que a variável é predita
A	Negrito e caixa alta indica que a variável é uma matriz
b	Negrito e caixa baixa indica que a variável é um vetor

Processo

A_R	Área de troca térmica do reator
C_A	Concentração de A no reator
C_{Ain}	Concentração de A na corrente de alimentação
C_B	Concentração de B no reator
C_p	Calor específico da mistura de reação
C_{p_k}	Calor específico do fluido de resfriamento
F_{in}	Vazão da corrente de alimentação
G_i	Função de transferência i
k_i	Velocidade da reação i
k_{i0}	Constante de velocidade da reação i
k_w	Coefficiente de transferência de calor da camisa de resfriamento
m_k	Massa do fluido de resfriamento
Q_k	Calor retirado pela camisa de resfriamento
T	Temperatura do fluido no interior do reator
T_{in}	Temperatura da corrente de alimentação
T_k	Temperatura do fluido de serviço da camisa de resfriamento
u	Ações de controle
V_R	Volume do Reator
ΔH_i	Entalpia das reação i
ρ	Massa específica da mistura de reação

Controle PID

k_c	Constante de ganho proporcional do controlador
k_{cr}	Ganho crítico
k_p	Constante de ganho do processo
P_{cr}	Período crítico
ω_{cr}	Frequência crítica
τ_D	Tempo da ação derivativa do controlador
τ_i	Tempo da ação integral do controlador
θ	Constante de tempo morto
λ	Parâmetro de ganho relativo

Controle Preditivo

J	Função objetivo ou custo
k	Instante de amostragem
M	Horizonte de controle
P	Horizonte de predição
r_i	Trajatória de referência da variável controlada i
R_w	Razão entre os pesos das variáveis controladas
y	Variável de saída
w_i	Peso das variável controladas i
λ_i	Peso da variável manipulada i
α_i	Parâmetro de ajuste da trajetória de referência da variável i

Redes Neurais

f	Quando referida a um neurônio denota função de ativação
n_h	Número de neurônios da camada escondida
n_i	Número de neurônios da camada de entrada
n_k	Número de neurônios da camada k

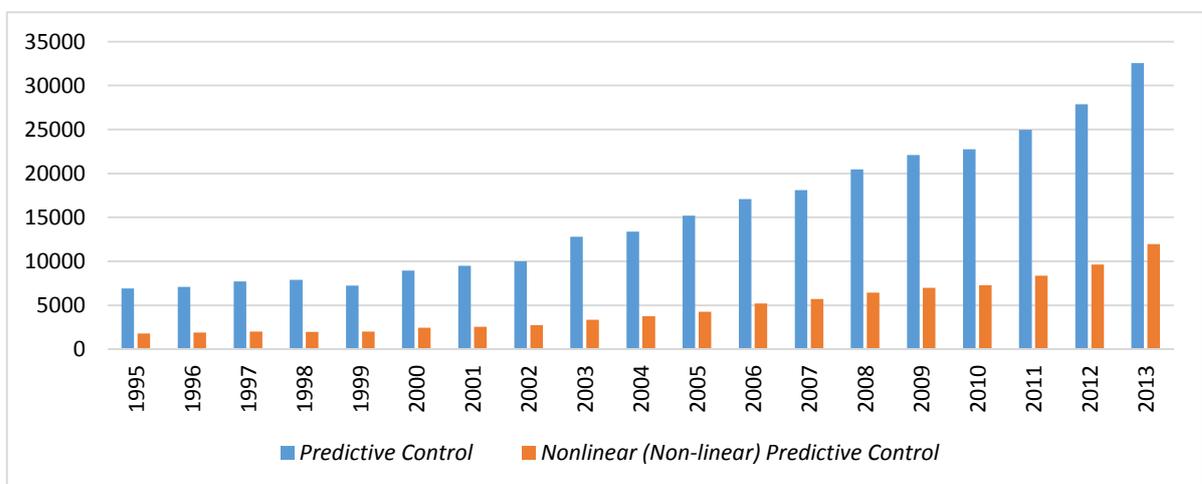
n_L	Número de neurônios da camada de saída
$s_{pi,k}$	Saída (ou ativação) de um neurônio i da camada k , para um padrão p
w_{jik}	Peso entre o neurônio j da camada $(k+1)$ e o neurônio i da camada precedente
$\lambda_{pj,k+1}$	Função auxiliar que indica a soma ponderada de todas entradas de um neurônio j da camada $(k+1)$, para um padrão p , mais o seu bias
σ_j	Largura (ou desvio-padrão) da função de ativação gaussiana de um neurônio j
$\theta_{j,k+1}$	“bias” (ou limite interno de ativação) do neurônio j da camada $(k+1)$

1 INTRODUÇÃO

1.1 Motivação

O desenvolvimento constante de novos processos e tecnologias associadas à constante busca do ser humano pela inovação e aperfeiçoamento de produtos, traz a necessidade de operações em regiões com características cada vez mais desafiadoras. De modo a garantir a estabilidade e segurança destes novos processos, a área de controle de processos também necessita de constante evolução.

Como parte desta evolução, o controle preditivo multivariável, desenvolvido inicialmente na década de 70, com os objetivos de minimizar os problemas de interação que ocorriam no nível do controle regulatório entre as malhas de controle, resolver os problemas de restrições atingidas no processo, e reduzir a variabilidade do processo em torno dos valores desejados, vem sendo cada vez mais estudado no meio acadêmico. A Figura 1, elaborada a partir de dados retirados do *Science Direct*, apresenta a evolução do número de publicações relacionados aos temas *Predictive Control* e *Nonlinear Predictive Control* ao longo dos últimos 20 anos.



Fonte: *Science Direct* - Adaptado

Figura 1 – Evolução das publicações relacionadas aos termos *Predictive Control* e *Nonlinear (Non-linear) Predictive Control*.

No âmbito de controle preditivo, os modelos não lineares, antes mais evitados devido às limitações computacionais, parecem ser o caminho para determinados processos com características não lineares, como multiplicidade de estados, inversão de ganho, etc., onde os modelos lineares tendem a não ser estáveis em toda a região de operação. Com a melhoria continuada do processamento dos computadores, os modelos não lineares têm sido cada vez mais avaliados por diversos pesquisadores desde a década de 90 (CHEN, 1997; HENSON, 1998; ALLGOWER *et al.*, 1999; MAYNE *et al.*, 2000; DOS SANTOS, 2007; MANENTI, 2011; entre outros). Pela Figura 1, é possível notar a evolução no número de publicações relacionadas a controladores preditivos não lineares, inclusive de maneira percentual em relação às publicações gerais de controle preditivo.

Devido à boa capacidade de representação de sistemas não lineares, conhecendo apenas dados de entrada e saída dos mesmos, além do baixo esforço computacional exigido, as redes neurais surgiram como importante ferramenta de modelagem para aplicação de controles preditivos. Diversos autores estudaram a utilização do controle preditivo baseado em redes neurais (DE SOUZA JR., 1993; NIKRAVESH *et al.*, 1997; SCHNITMAN, 1998; MONTANHEIRO, 2004; MAMANI, 2004; ANURADHA *et al.*, 2009; PROTTESS, 2009; entre outros).

1.2 Objetivo

O presente trabalho tem como objetivo investigar a funcionalidade de um controle preditivo não linear multivariável baseado em redes neurais no controle de um sistema com característica não linear.

Como forma de comparação, buscando avaliar possíveis falhas no modelo utilizando redes neurais, foram feitas simulações considerando a predição pelo próprio sistema de equações diferenciais, que representa um modelo de predição perfeita do processo. Investigou-se também a influência de alguns parâmetros chaves para o funcionamento dos controladores, tais como tempo de amostragem, horizontes de controle de predição, entre outros.

O processo escolhido para estudo trata-se do reator CSTR com cinética de Van de Vusse (VUSSE, 1964). O mesmo é empregado como *benchmark* no estudo

de sistemas de controle devido ao seu comportamento não linear, apresentando inversão de ganho, multiplicidade de estados e comportamento de fase não mínima.

1.3 Organização do Trabalho

Inicialmente, no Capítulo 2, é realizada uma revisão bibliográfica sobre controle preditivo e suas principais características. São expostas de forma resumida as principais técnicas de controle preditivo linear. Já no controle preditivo não linear, é dada uma maior atenção aos modelos baseados em redes neurais, objetivo central deste trabalho.

No Capítulo 3, é descrito o modelo do processo escolhido para estudos dessa dissertação. O processo é então submetido a análises dinâmicas e estacionárias para identificação das características não lineares que justificam a sua escolha. Ao final do capítulo, é feita uma revisão bibliográfica de trabalhos de controle relacionados ao processo escolhido.

No Capítulo 4, são aplicadas técnicas de controle PID multimalhas para serem utilizadas como referência na análise de desempenho dos controladores preditivos, além de demonstrar a ineficiência dos controladores PID em sistemas não lineares.

O Capítulo 5 apresenta a identificação do modelo do processo utilizando redes neurais. O objetivo é obter redes neurais capazes de prever o comportamento do processo ao longo de um horizonte de predição a partir de informações presentes e passadas das variáveis manipuladas e controladas.

No Capítulo 6, são aplicadas técnicas de controle preditivo baseadas em redes neurais e nas próprias equações diferenciais do processo. A influência de cada parâmetro dos controladores é analisada visando obter a melhor sintonia. Ao final, diversos cenários de alteração de *setpoint* e perturbações ao processo são simulados utilizando os diferentes tipos de controladores para comparação do desempenho dos mesmos.

Por fim, o Capítulo 7 elenca as conclusões alcançadas no presente trabalho, bem como sugestões para trabalhos futuros.

2 CONTROLE PREDITIVO

2.1 Introdução

O controle preditivo baseia-se na utilização de um modelo representativo do processo capaz de prever seu comportamento ao longo de um horizonte pré-determinado. As ações de controle são tomadas de forma a manter o processo o mais próximo possível de uma trajetória de referência.

A principal diferença entre o controle preditivo e o controle PID, tradicional e mais utilizado na indústria, está na forma como a ação de controle é projetada. No controle PID convencional, a ação de controle é projetada a partir do erro presente e acumulado nas saídas do sistema, já no controle preditivo a ação de controle é projetada com base nos erros futuros do processo (DURAISKI, 2001).

Embora idealizado inicialmente para aplicações na indústria petrolífera, atualmente, o controle preditivo é empregado nas mais diversas áreas, não somente da indústria, mas também em outras áreas do conhecimento humano, como a medicina (anestesia, controle de pressão sanguínea), mostrando a evolução prática destas estratégias e comprovando que em breve devem substituir a maioria dos controladores clássicos utilizados, que, muitas vezes, mostram-se ineficientes em ambientes complexos (DOS SANTOS, 2007).

A forma básica e mais conhecida do controle preditivo é o controle preditivo baseado em modelo (MPC do inglês, *Model Predictive Control*). O MPC proporcionou importantes vantagens, entre elas (SEBORG *et al.*, 2004; CAMACHO & BORDONS, 2007; MOSCA, 1995):

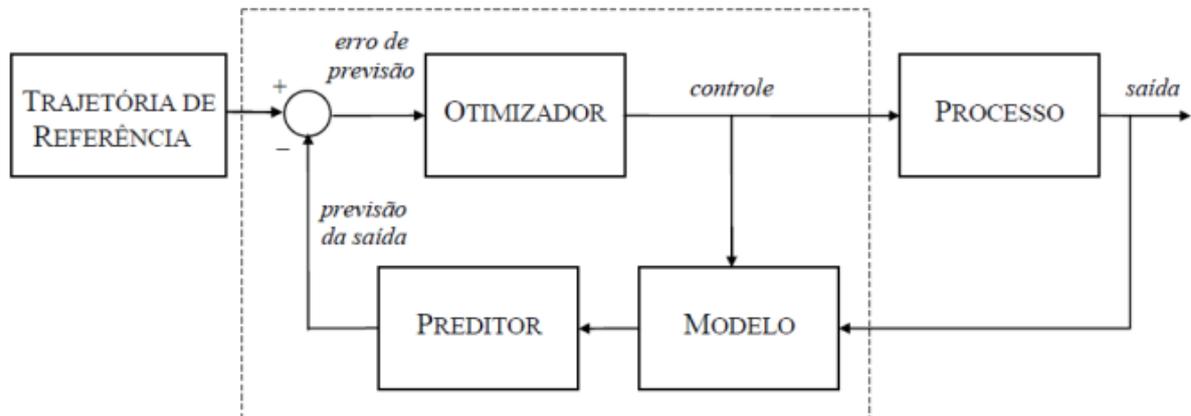
- O modelo do processo captura as interações dinâmicas e estáticas entre as variáveis controladas, manipuladas e perturbações.

- O tratamento de restrições pode ser incluído durante o projeto do controlador.
- Permite a compensação de perturbações mensuráveis, corrigindo-as com uma ação de controle tipo *feedforward*.
- Pode ser implementado não só como um algoritmo de controle regulatório, mas também como uma estratégia de controle supervisorio, ou mesmo em um nível superior abordando os problemas de otimização empregando diferentes funções objetivos.
- Pode ser usado em uma grande variedade de processos, desde aqueles com dinâmica simples até os de dinâmica mais complexas, incluindo sistemas não lineares, multivariáveis, instáveis e de fase não mínima.
- As ações de controle podem estar em concordância com o cálculo dos pontos ótimos de operação.
- Modelos de predição precisos podem antecipar alertas de problemas potenciais.
- É uma metodologia aberta, baseada em princípios básicos, o que permite extensões futuras, contribuições e incorporação de novos desenvolvimentos, principalmente quanto ao modelo de predição e aos critérios de otimização, entre outros.

A Figura 2 apresenta a estrutura básica do MPC, onde os principais elementos envolvidos são:

- Trajectoria de Referência: Representa o comportamento do sinal desejado para a saída no futuro.
- Modelo: Modelo matemático do processo que deve ser capaz de representar o seu comportamento dinâmico de forma suficientemente precisa, podendo ser linear ou não linear, dependendo da necessidade. Pode ser atualizado através de métodos de identificação online conferindo ao controlador uma característica adaptativa.
- Preditor: Fornece através do modelo matemático uma previsão da saída futura com base na informação atual da planta.
- Otimizador: Minimiza a função objetivo a cada período de amostragem de forma a obter uma ação de controle que garanta um desempenho

adequado ao sistema. A função a ser minimizada pode contemplar, além de parcelas associadas ao erro futuro e ao incremento no sinal de controle, outros termos que forneçam ao controlador propriedades que melhorem o seu desempenho frente às particularidades do processo.

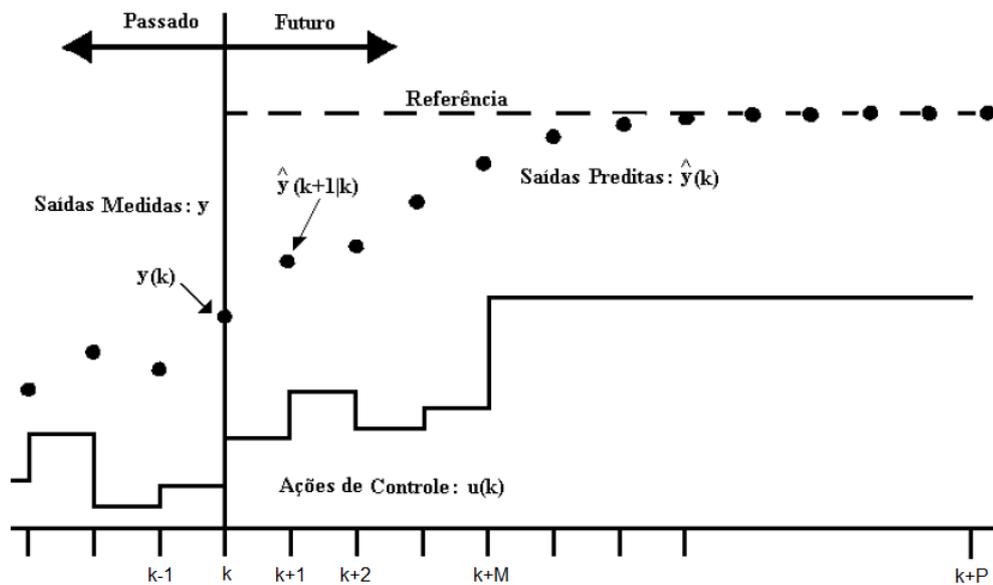


Fonte: DOS SANTOS (2007)

Figura 2 – Estrutura básica do MPC.

A Figura 3 apresenta um esquemático do conceito básico da estratégia MPC. No instante de amostragem k , o comportamento da variável controlada é previsto ao longo do horizonte de predição (P) a partir dos dados medidos nos instantes anteriores. As ações de controle ($u(k)$) no horizonte de controle (M) são calculadas de forma a minimizar o erro entre as saídas previstas ($y(k+1,2,\dots,P)$) e a trajetória de referência (*setpoint* desejado).

Apenas a primeira ação de controle calculada é aplicada na planta, sendo as demais descartadas (podendo servir de estimativas iniciais no otimizador). No próximo instante de amostragem, todo o processo é repetido baseado nas novas informações medidas. Tal princípio é conhecido como “Princípio do Horizonte Móvel” (*Receding Horizon*).



Fonte: DE SOUZA JR. (1989) - Adaptado

Figura 3 – Representação esquemática do conceito básico do MPC.

A lei de controle preditivo é obtida através da minimização de uma função objetivo, também conhecida como função custo, que quantifica a diferença entre a saída predita e a trajetória de referência. A função objetivo pode também conter restrições intrínsecas do processo, tais como evitar variações bruscas nas variáveis manipuladas e controladas. A seguir, um exemplo típico de função objetivo:

$$J = \sum_{j=1}^P [\hat{y}(k+j) - r(k+j)]^2 + \lambda \sum_{i=1}^M \Delta u^2(k+i-1) \quad (1)$$

Segundo Cavalcanti (2003), a função objetivo tem que se adequar aos requisitos do controlador, tais como tempo de estabilização, sobressinal, tempo de subida, entre outros.

2.2 Breve Histórico

O controle preditivo baseado em modelo teve seu início em algoritmos desenvolvidos por dois grupos diferentes (RICHALET *et al.*, 1978; CUTLER & RAMAKER, 1979), independentemente, no final da década de 70, ainda que as ideias de horizonte descendente e controle preditivo baseado em modelo possam ser rastreadas nos anos 60 (GARCIA *et al.*, 1989). O algoritmo desenvolvido por Richalet *et al.* (1978), engenheiros da ADERSA, foi comercializada com o nome

IDCOM, já a técnica desenvolvida por Cutler & Ramaker (1979), engenheiros da Shell Oil, deu origem a um dos algoritmos mais utilizados na indústria química, o Controle por Matriz Dinâmica (DMC).

Os algoritmos originais IDCOM e DMC propiciavam excelentes desempenhos em processos multivariáveis sem restrições, porém não suportavam problemas com restrições, presentes em grande parte das aplicações industriais. Para solucionar essa fraqueza, engenheiros da Shell Oil (GARCIA & MORSHEDI, 1986) colocaram o algoritmo DMC como um programa quadrático onde as restrições apareciam explicitamente.

No final da década de 80, um MPC adaptativo foi desenvolvido por Clarke *et al.* (1987), conhecido como Controle Preditivo Generalizado (GPC), cuja base teórica parece ser bastante similar ao DMC, apesar de existirem diferenças significativas entre eles. Enquanto o DMC foi desenvolvido para tratar problemas multivariáveis típicos de indústrias químicas, o GPC foi concebido para oferecer uma nova alternativa de controle adaptativo, que em sua maioria utilizava modelos de entrada/saída (funções de transferência). No GPC, os aspectos estocásticos desempenham um papel fundamental, enquanto a formulação original do DMC era completamente determinística (MORARI & LEE, 1999).

Ao longo dos anos seguintes, muitas variações dos algoritmos originais surgiram, IDCOM-M, HIECON, SMCA, SMOC, entre outros (QIN & BADGWELL, 2003). Segundo Morari & Lee (1999), no final dos anos 90, os algoritmos MPC, em sua maioria, eram formulados na forma de espaço de estados.

2.3 Controle Preditivo Linear

A utilização de MPC baseados em modelos lineares é bastante comum no meio industrial, pois além de se tratarem de modelos mais conhecidos e testados no meio acadêmico, muitas vezes torna-se necessário o emprego de um modelo simplificado para que todos os cálculos envolvidos sejam executados dentro de um intervalo de amostragem que possibilite o controle em tempo real. A opção por um modelo linear para representação da planta deve ser a escolha preferencial sempre

que for possível que o controlador alcance o desempenho desejado pelo usuário (DOS SANTOS, 2007).

Qin & Badgwell (2003) apresentaram um estudo dos principais MPC comerciais e suas aplicações em diferentes tipos de indústrias. A Tabela 1, apresenta os dados levantados pelos autores referentes à utilização de MPC lineares por diferentes áreas industriais. Os dados são do início dos anos 2000, mas servem para mostrar o grande número de aplicações de MPC no meio industrial.

Tabela 1 – Aplicações comerciais de MPC linear.

Área	Total
Refinaria	1985
Petroquímica	550
Química	144
Papel e Celulose	68
Ar e Gás	10
Utilidades	14
Metalurgia	37
Alimentos	51
Polímeros	17
Fornos	45
Aeroespacial	13
Automotiva	7
Outras	1601
Total	4542

Fonte: QIN & BADGWELL (2003) - Adaptado

A partir do conceito básico do controle preditivo, foram estabelecidas na literatura diversas técnicas de MPC linear. Parte destas são apenas variações ou adaptações elaboradas de forma a atender aos requisitos específicos de um determinado sistema. No entanto, destacam-se três dessas abordagens:

- Controle por Matriz Dinâmica (DMC, do inglês *Dynamic Matrix Control*).
- Controle Preditivo Generalizado (GPC, do inglês *Generalized Predictive Control*).
- Modelo em Espaço de Estados.

2.3.1 Controle por Matriz Dinâmica (DMC)

O algoritmo DMC foi desenvolvido por Cutler & Ramaker (1979), engenheiros da *Shell Oil*, e tem sido largamente empregado no mundo industrial, principalmente em indústrias petroquímicas (QIN & BADGWELL, 2003). O DMC emprega um método não paramétrico. Atualmente, o DMC é mais do que um algoritmo e parte de seu sucesso se deve ao fato de seus produtos comerciais cobrirem uma série de tópicos como identificação ou otimização da planta.

O DMC tem como principais características (QIN & BADGWELL, 1997):

- Resposta linear ao degrau como modelo da planta;
- Função objetivo quadrática em um horizonte de predição finito;
- Saídas futuras da planta são especificadas para rastreamento de *setpoint*;
- Entradas ótimas são calculadas como solução de um problema de mínimos quadrados.

O equacionamento apresentado a seguir de forma resumida foi descrito por Bequette (2002). O modelo de resposta ao degrau, conhecido como FSR (do inglês, *Finite Step Response*) é obtido através da aplicação de um degrau unitário em um processo operando em estado estacionário. Os coeficientes do modelo (s_i) são os valores de saída em cada instante de tempo, logo o modelo \mathbf{s} pode ser representado por um vetor de coeficientes:

$$\mathbf{s} = [s_1 \quad s_2 \quad s_3 \quad s_4 \quad s_5 \quad \dots \quad s_N]^T \quad (2)$$

O valor s_N é escolhido de maneira que o estado estacionário seja alcançado. A partir dos coeficientes é possível obter a predição do modelo através da equação:

$$\hat{y}_k = s_1 \Delta u_{k-1} + s_2 \Delta u_{k-2} + \dots + s_{N-1} \Delta u_{k-N+1} + s_N u_{k-N} = \sum_{i=1}^{N-1} s_i \Delta u_{k-i} + s_N u_{k-N} \quad (3)$$

A diferença entre a predição do modelo e o valor real medido é tratado como distúrbio, sendo representado conforme Equação 4.

$$d_k = y_k - \hat{y}_k \quad (4)$$

Através da manipulação da Equação 4, obtêm-se a predição corrigida (\hat{y}_k^c):

$$\hat{y}_k^c = \hat{y}_k + d_k \quad (5)$$

O caminho normalmente seguido para abordar as perturbações futuras é considerar que são iguais a do instante de amostragem anterior. Dessa forma, a Equação 5 pode ser reescrita na forma matricial por:

$$\begin{bmatrix} \hat{y}_{k+1}^c \\ \hat{y}_{k+2}^c \\ \vdots \\ \hat{y}_{k+2}^c \\ \vdots \\ \hat{y}_{k+P}^c \end{bmatrix} = \begin{bmatrix} s_1 & 0 & 0 & \cdots & 0 & 0 \\ s_2 & s_1 & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & & & & \\ s_j & s_{j-1} & s_{j-2} & \cdots & \cdots & s_{j-M+1} \\ \vdots & \vdots & \vdots & & & \\ s_P & s_{P-1} & s_{P-2} & \cdots & \cdots & s_{P-M+1} \end{bmatrix} \begin{bmatrix} \Delta u_k \\ \Delta u_{k+1} \\ \vdots \\ \Delta u_{k+M-2} \\ \Delta u_{k+M-1} \end{bmatrix} + \begin{bmatrix} s_2 & s_3 & s_4 & \cdots & s_{N-2} & s_{N-1} \\ s_3 & s_4 & s_5 & \cdots & s_{N-1} & 0 \\ \vdots & \vdots & & & 0 & 0 \\ s_{j+1} & s_{j+2} & \cdots & s_{N-1} & 0 & 0 \\ \vdots & \vdots & \vdots & & \vdots & \\ s_{P+1} & s_{P+2} & \cdots & 0 & \cdots & 0 \end{bmatrix} \begin{bmatrix} \Delta u_{k-1} \\ \Delta u_{k-2} \\ \vdots \\ \Delta u_{k-N+3} \\ \Delta u_{k-N+2} \end{bmatrix} + s_N \begin{bmatrix} u_{k-N+1} \\ u_{k-N+2} \\ \vdots \\ u_{k-N+P} \end{bmatrix} + \begin{bmatrix} d_{k+1} \\ d_{k+2} \\ \vdots \\ d_{k+P} \end{bmatrix} \quad (6)$$

Utilizando a notação matricial:

$$\hat{y}^c = \mathbf{S}_f \Delta \mathbf{u}_f + \mathbf{S}_{\text{past}} \Delta \mathbf{u}_{\text{past}} + s_N \mathbf{u}_p + \hat{\mathbf{d}} \quad (7)$$

O primeiro termo da Equação 7 é referente aos efeitos dos movimentos atuais e futuros, o segundo e terceiro termos são referentes aos efeitos dos movimentos passados e o ultimo termo referente aos distúrbios preditos. A saída predita corrigida é composta por uma resposta forçada (contribuição das ações de controle atuais e futuras) e uma resposta livre (saída esperada se nenhuma ação de controle for tomada). A diferença entre a trajetória de referência (\mathbf{r}) e as predições futuras é obtida por:

$$\mathbf{e}^c = \mathbf{r} - \hat{y}^c = \mathbf{r} - [\mathbf{S}_{\text{past}} \Delta \mathbf{u}_{\text{past}} + s_N \mathbf{u}_p + \hat{\mathbf{d}}] - \mathbf{S}_f \Delta \mathbf{u}_f \quad (8)$$

A Equação 8 pode ser reescrita por:

$$\mathbf{e}^c = \mathbf{e} - \mathbf{S}_f \Delta \mathbf{u}_f \quad (9)$$

A função objetivo quadrática pode ser escrita, em sua forma matricial:

$$J = (\mathbf{e}^c)^T \mathbf{e}^c + (\Delta \mathbf{u}_f)^T \mathbf{W} \Delta \mathbf{u}_f \quad (10)$$

Substituindo a Equação 9 na Equação 10, tem-se:

$$J = (\mathbf{e} - \mathbf{S}_f \Delta \mathbf{u}_f)^T (\mathbf{e} - \mathbf{S}_f \Delta \mathbf{u}_f) + (\Delta \mathbf{u}_f)^T \mathbf{W} \Delta \mathbf{u}_f \quad (11)$$

A solução do problema de otimização (derivando em relação as ações de controle e igualando a zero) acima resulta:

$$\Delta \mathbf{u}_f = \underbrace{(\mathbf{S}_f^T \mathbf{S}_f + \mathbf{W})^{-1} \mathbf{S}_f^T}_{\mathbf{K}} \mathbf{e} = \mathbf{K} \mathbf{e} \quad (12)$$

Como somente a primeira ação é implementada, basta multiplicar apenas a primeira linha da matriz \mathbf{K} pelo vetor de erros \mathbf{e} para obter as ações de controle.

Os parâmetros de sintonia do DMC permitem uma maior flexibilidade de projeto para o sistema controlado. No entanto, algumas peculiaridades devem ser levadas em conta na sua seleção, conforme resumido por Dos Santos (2007):

- Início de horizonte de predição: Normalmente é igual a um, mas nos casos onde o atraso de transporte é perfeitamente conhecido, pode ser ajustado;
- Término do horizonte de predição: Geralmente, é tal que este seja maior do que o tempo de subida porém não superior ao tempo de estabilização do processo. Para a maioria dos processos estáveis em malha aberta, a dinâmica de malha fechada torna-se mais rápida com sua diminuição. O aumento do horizonte de predição final provoca um aumento da robustez do sistema quanto à presença de dinâmicas não-modeladas aumentando, porém, o esforço computacional;
- Horizonte de controle: Valores elevados, além de aumentar o esforço computacional, aumentam a agressividade da ação de controle. Para

sistemas estáveis em malha aberta, $M = 1$ mostra-se, geralmente, adequado. Na prática o valor de M deve ser o menor possível que permita um desempenho satisfatório do sistema;

- Ponderação do controle: A introdução desta ponderação faz com que a magnitude do sinal de controle seja levada em conta na função custo a ser minimizada. Isto provoca uma diminuição dos níveis do sinal de controle podendo causar, também, aumento na sobre-elevação da saída do sistema. A ponderação W com um valor diferente de zero melhora o condicionamento da matriz obtida no desenvolvimento da lei de controle, possibilitando sua inversão, além de aumentar a robustez do sistema quando sujeito a incertezas de modelagem (BANERJEE E SHAH, 1995).

2.3.2 Controle Preditivo Generalizado (GPC)

O método de controle preditivo generalizado (GPC) foi proposto por Clarke *et al.* (1987), tendo se tornado um dos métodos de MPC mais populares tanto no meio industrial como no meio acadêmico. O GPC vem sendo utilizado em muitas aplicações industriais, apresentando bons desempenhos e certo grau de robustez (CAMACHO & BORDON, 2007).

O controlador GPC possibilita tratar processos que possuam atrasos de transporte desconhecidos ou variantes, sistemas sob restrições, não linearidades, sistemas de fase não mínima, bem como plantas instáveis em malha aberta. Assim como o DMC, na prática, somente o primeiro sinal de controle é aplicado e, a cada iteração, um novo problema de minimização é resolvido (CLARKE *et al.*, 1987).

A ideia básica do GPC é calcular uma sequência de ações futuras de modo a minimizar uma função custo definida num horizonte de predição. As predições são realizadas através de um modelo paramétrico do tipo CARIMA. Camacho & Bordon (2007) apresentaram o equacionamento do método GPC, que se encontra resumido a seguir.

Para o cálculo das predições supõe-se que o comportamento do sistema pode ser representado pelo modelo auto-regressivo do tipo CARIMA:

$$A(z^{-1})y(t) = B(z^{-1})z^{-d}u(t-1) + C(z^{-1})\frac{e(t)}{\Delta} \quad (\Delta = 1 - z^{-1}) \quad (13)$$

Em que $u(t)$ e $y(t)$ são, respectivamente, as ações de controle aplicadas e as saídas obtidas, $e(t)$ é um ruído de média nula e d é o tempo morto do sistema. A , B e C são polinômios no operador de atraso:

$$A(z^{-1}) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{na}z^{-na} \quad (14)$$

$$B(z^{-1}) = b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_{nb}z^{-nb} \quad (15)$$

$$C(z^{-1}) = 1 + c_1z^{-1} + c_2z^{-2} + \dots + c_{nc}z^{-nc} \quad (16)$$

A função custo a ser minimizada no algoritmo GPC é da forma:

$$J = \sum_{j=P_1}^{P_2} \delta(j)[\hat{y}(t+j|t) - r(t+j)]^2 + \sum_{j=1}^M \lambda(j)[\Delta u(t+j-1)]^2 \quad (17)$$

Em que $\hat{y}(t+j|t)$ é a predição do estado j no tempo t , P_1 e P_2 são os limites inferior e superior do horizonte de predição, M é o horizonte de controle, $r(t+j)$ é a trajetória de referência, $\delta(t)$ e $\lambda(t)$ são as ponderações. Normalmente, $\delta(t)$ é considerada 1 e $\lambda(t)$ considerada constante.

Após manipulações na Equação 13, Camacho & Bordons (2007) mostraram que a predição ótima pode ser obtida por:

$$\hat{y}(t+j|t) = G_j(z^{-1})\Delta u(t+j-d-1) + F_j(z^{-1})y(t) \quad (18)$$

Em que $G_j(z^{-1}) = E_j(z^{-1})B(z^{-1})$. Isto implica que a predição ótima pode ser calculada como uma combinação linear das saídas anteriores do processo e dos controles passados e futuros. Os polinômios E_j e F_j podem ser calculados recursivamente usando o procedimento da divisão de polinômios ou outros métodos.

Como o sistema considerado tem um tempo morto de d períodos de amostragem, o sinal de saída vai ser influenciado pelo sinal de entrada após um período de $d+1$. Os valores dos horizonte de predição e controle podem ser definidos como $P_1 = d+1$, $P_2 = d+N$ e $M = N$. Para obter as ações de controle que minimizam a função custo (J), devem ser consideradas as N predições ótimas:

$$\begin{aligned}
\hat{y}(t+d+1|t) &= G_{d+1}\Delta u(t) + F_{d+1}y(t) \\
\hat{y}(t+d+2|t) &= G_{d+2}\Delta u(t) + F_{d+2}y(t) \\
&\vdots \\
\hat{y}(t+d+P|t) &= G_{d+P}\Delta u(t) + F_{d+P}y(t)
\end{aligned} \tag{19}$$

Que pode ser escrito na forma vetorial como:

$$\hat{\mathbf{y}} = \mathbf{G}\Delta\mathbf{u} + \mathbf{F}(z^{-1})y(t) + \mathbf{G}'(z^{-1})\Delta u(t-1) \tag{20}$$

Em que:

$$\hat{\mathbf{y}} = \begin{bmatrix} \hat{y}(t+d+1|t) \\ \hat{y}(t+d+1|t) \\ \vdots \\ \hat{y}(t+d+N|t) \end{bmatrix} \quad \Delta\mathbf{u} = \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+N-1) \end{bmatrix} \quad \mathbf{G} = \begin{bmatrix} g_0 & 0 & \cdots & 0 \\ g_1 & g_0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ g_{N-1} & g_{N-2} & \cdots & g_0 \end{bmatrix}$$

$$\mathbf{G}'(z^{-1}) = \begin{bmatrix} (G_{d+1}(z^{-1}) - g_0)z \\ (G_{d+2}(z^{-1}) - g_0 - g_1z^{-1})z^2 \\ \vdots \\ (G_{d+N}(z^{-1}) - g_0 - g_1z^{-1} - \cdots - g_{N-1}z^{-(N-1)})z^N \end{bmatrix} \quad \mathbf{F}(z^{-1}) = \begin{bmatrix} F_{d+1}(z^{-1}) \\ F_{d+2}(z^{-1}) \\ \vdots \\ F_{d+N}(z^{-1}) \end{bmatrix}$$

Observa-se que os dois últimos termos só dependem do passado e podem ser agrupados num único vetor, definido como a resposta livre do sistema (\mathbf{f}).

$$\hat{\mathbf{y}} = \mathbf{G}\Delta\mathbf{u} + \mathbf{f} \tag{21}$$

Em termos matriciais, a Equação 17, considerando $\delta(t)=1$ e $\lambda(t)=\lambda$ constantes, pode ser escrita como:

$$J = (\mathbf{G}\Delta\mathbf{u} + \mathbf{f} - \mathbf{r})^T (\mathbf{G}\Delta\mathbf{u} + \mathbf{f} - \mathbf{r}) + \lambda \mathbf{u}^T \mathbf{u} \tag{22}$$

Em que:

$$\mathbf{w} = [w(t+d+1) \quad w(t+d+2) \quad \cdots \quad w(t+d+N)]^T$$

A Equação 22 pode ser escrita como uma forma quadrática:

$$J = \frac{1}{2} \Delta\mathbf{u}^T \mathbf{H} \Delta\mathbf{u} + \mathbf{b}^T \Delta\mathbf{u} + f_0 \tag{23}$$

Em que:

$$\begin{aligned}\mathbf{H} &= 2(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I}) \\ \mathbf{b}^T &= 2(\mathbf{f} - \mathbf{r})^T \mathbf{G} \\ f_0 &= (\mathbf{f} - \mathbf{r})^T (\mathbf{f} - \mathbf{r})\end{aligned}$$

O mínimo de J pode ser calculado, quando não há restrições, igualando o gradiente de J a zero, que resulta:

$$\Delta \mathbf{u} = -\mathbf{H}^{-1} \mathbf{b} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T (\mathbf{r} - \mathbf{f}) \quad (24)$$

Como o algoritmo GPC também considera o princípio do horizonte móvel, apenas o primeiro sinal de controle é aplicado (primeiro elemento do vetor $\Delta \mathbf{u}$), dessa forma, a lei final de controle é dada por:

$$\Delta u(t) = \mathbf{K}(\mathbf{r} - \mathbf{f}) \quad (25)$$

Em que \mathbf{K} é a primeira linha da matriz $(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T$. Caso as ponderações não sejam consideradas constantes, \mathbf{K} será a primeira linha da matriz $(\mathbf{G}^T \mathbf{Q}_\delta \mathbf{G} + \mathbf{Q}_\lambda)^{-1} \mathbf{G}^T \mathbf{Q}_\delta$, onde \mathbf{Q}_δ e \mathbf{Q}_λ são matrizes diagonais com valores das ponderações na diagonal.

2.3.3 Modelo em Espaço de Estados

Embora os modelos de respostas ao degrau, utilizados pelo DMC, sejam práticos e fáceis de serem obtidos diretamente do processo, nem sempre traduzem com fidelidade o seu comportamento. Nos casos onde se dispõe de um modelo fenomenológico, é possível lineariza-lo expandindo as funções não lineares em séries de Taylor truncadas no termo linear. O mesmo é feito para as funções que representam as saídas do sistema, gerando assim a representação em espaços de estados (BEQUETTE, 2002).

Os modelos de espaços de estados podem ser utilizados na formulação de problemas de controle preditivo, em processos monovariváveis ou multivariáveis,

podendo ser estendidos para processos não lineares. A representação do caso linear em espaços de estados é da forma (CAMACHO & BORDONS, 2007):

$$\begin{aligned} \mathbf{x}(t+1) &= \mathbf{A}\mathbf{x}(t) + \mathbf{B}u(t) \\ y(t) &= \mathbf{C}\mathbf{x}(t) \end{aligned} \quad (26)$$

Em modelos de uma única entrada e uma única saída (SISO), $y(t)$ e $u(t)$ são escalares, enquanto $\mathbf{x}(t)$ é um vetor de estados. Nos processos de múltiplas entradas e múltiplas saídas (MIMO), a formulação é semelhante, porém \mathbf{y} e \mathbf{u} são vetores. Por simplificação, foi considerado apenas o caso SISO para apresentação da formulação do MPC com modelo de espaço de estados.

Para que o modelo seja utilizado no controlador preditivo, é necessário que ele possa determinar todos os valores preditos para alguns instantes de tempo futuros. Além disso, é mais conveniente que o modelo utilize as variáveis na forma de deltas (variação ponto a ponto). Definindo um novo vetor de estado $\bar{\mathbf{x}}(t) = [\mathbf{x}(t) \quad u(t-1)]^T$, a Equação 26 escrita em variáveis delta é da forma (CAMACHO & BORDONS, 2007):

$$\begin{aligned} \bar{\mathbf{x}}(t+1) &= \mathbf{M}\bar{\mathbf{x}}(t) + \mathbf{N}\Delta u(t) \\ y(t) &= \mathbf{Q}\bar{\mathbf{x}}(t) \end{aligned} \quad (27)$$

Em que:

$$\mathbf{M} = \begin{bmatrix} \mathbf{A} & \mathbf{B} \\ \mathbf{0} & \mathbf{I} \end{bmatrix}; \quad \mathbf{N} = \begin{bmatrix} \mathbf{B} \\ \mathbf{I} \end{bmatrix}; \quad \mathbf{Q} = [\mathbf{C} \quad \mathbf{0}]$$

As predições ao longo de um horizonte de predição podem ser obtidas utilizando a Equação 27 recursivamente.

$$\hat{y}(t+j) = \mathbf{Q}\mathbf{M}^j \hat{\mathbf{x}}(t) + \sum_{i=0}^{j-1} \mathbf{Q}\mathbf{M}^{j-i-1} \mathbf{N}\Delta u(t+i) \quad (28)$$

Como pode ser observado as predições da variável de saída dependem de uma estimacão dos vetores de estado. Caso o vetor de estados não esteja disponível, um estimador deve ser incluído (CAMACHO & BORDONS, 2007).

$$\hat{\mathbf{x}}(t|t) = \hat{\mathbf{x}}(t|t-1) + K(y_m(t) - y(t|t-1)) \quad (29)$$

Em que $y_m(t)$ é a saída medida. Caso a planta seja submetida a um distúrbio afetando o processo e a saída com matrizes de covariância conhecidas, o observador passa a ser um filtro de Kalman e o ganho K é calculado através da equação de Riccati (CAMACHO & BORDONS, 2007).

Dessa forma, as P previsões ao longo do horizonte podem ser expressas na forma matricial por:

$$\hat{\mathbf{y}} = \mathbf{F}\hat{\mathbf{x}}(t) + \mathbf{H}\Delta\mathbf{u} \quad (30)$$

Em que:

$$\Delta\mathbf{u} = \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+M-1) \end{bmatrix}; \quad \mathbf{F} = \begin{bmatrix} \mathbf{QM} \\ \mathbf{QM}^2 \\ \vdots \\ \mathbf{QM}^P \end{bmatrix}; \quad \mathbf{H} = \begin{bmatrix} \mathbf{QN} & 0 & \dots & 0 \\ \mathbf{QMN} & \mathbf{QN} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{QM}^{P-1}\mathbf{N} & \mathbf{QM}^{P-2}\mathbf{N} & \dots & \mathbf{QN} \end{bmatrix}$$

O primeiro termo na Equação 30 depende do estado atual que é conhecido no instante t , enquanto o segundo termo depende das ações de controle futuras, que são calculadas minimizando a função objetivo, semelhante a apresentada da Equação 17, que (no caso de $\delta(j)=1$ e $\lambda(j)=\lambda$) pode ser escrita na forma matricial como:

$$J = (\mathbf{H}\Delta\mathbf{u} + \mathbf{F}\hat{\mathbf{x}}(t) - \mathbf{r})^T (\mathbf{H}\Delta\mathbf{u} + \mathbf{F}\hat{\mathbf{x}}(t) - \mathbf{r}) + \lambda\Delta\mathbf{u}^T \Delta\mathbf{u} \quad (31)$$

Para o caso sem restrições, uma solução analítica pode ser calculada:

$$\Delta\mathbf{u} = (\mathbf{H}^T \mathbf{H} + \lambda \mathbf{I})^{-1} \mathbf{H}^T (\mathbf{r} - \mathbf{F}\hat{\mathbf{x}}(t)) \quad (32)$$

Como o princípio do horizonte móvel é utilizado, somente o primeiro elemento do vetor $\Delta\mathbf{u}$ é aplicado na planta. Vale ressaltar que um estimador de estados é necessário, já que a lei de controle depende de $\hat{\mathbf{x}}(t)$.

2.4 Controle Preditivo Não Linear

O controle preditivo baseado em modelos não lineares, também conhecido como NMPC (do inglês, *Nonlinear Model Predictive Control*), vem recebendo grande atenção desde o início dos anos 90, tanto no meio industrial como no meio acadêmico. Conforme visto na Figura 1, o número de trabalhos relativos a controles preditivos não lineares vem aumentando constantemente. Segundo Henson & Seborg (1997), o principal motivo desse crescimento é o desempenho inadequado apresentado pelos controladores lineares em muitos sistemas não lineares ou que operam numa faixa ampla de condições. Ainda segundo os autores, outro fator determinante para esse aumento, é a melhoria contínua na capacidade dos *softwares* e *hardwares* voltados para controle, tornando possível incorporar modelos complexos.

Qin & Badgwell (2003) e Bauer & Craig (2008) apresentaram a evolução também das aplicações industriais de NMPC. Manenti (2011) resumiu as principais razões para o aumento no número de aplicações de NMPC no meio industrial:

- Intrinsecamente capaz de gerenciar não linearidades na dinâmica dos processos e conseqüentemente nos lucros;
- Pode ser baseado tanto em modelos fundamentais como em modelos semi-empíricos;
- Permite resolver de forma eficaz e simultânea seu próprio paradigma (apenas problemas quadráticos) e a otimização dinâmica em tempo real (problema econômico) através do uso de restrições e limites nas variáveis controladas e manipuladas.

A formulação do problema de controle para metodologia não linear é análoga à abordagem linear, exceto que a predição do comportamento futuro do processo é feita por um modelo dinâmico não linear. As ações de controle são calculadas através da solução de um problema de programação não linear. Para justificar a sua utilização, os benefícios propiciados pela abordagem não linear devem superar o inerente aumento de complexidade quando comparado aos métodos lineares (MELEIRO, 2002).

Segundo Camacho & Bordons (2007), não há nada no conceito básico do MPC contra o uso de modelos não lineares, no entanto, a extensão das ideias do MPC para processos não lineares não se trata de um problema trivial, possuindo muitas dificuldades, entre elas:

- A disponibilidade de modelos não lineares a partir de dados experimentais ainda é uma questão em aberto. Modelos existentes não parecem resolver o problema de maneira geral. Por outro lado, modelos fundamentais (balanços de massa e energia) nem sempre são considerados viáveis.
- O problema de otimização é não convexo, com resolução muito mais difícil que problemas de programação quadrática. Problemas de mínimos locais podem influenciar não só a qualidade do controlador, como também levar a problemas de instabilidade.
- A dificuldade nos problemas de otimização implica num aumento significativo no tempo de computação, o que pode restringir a utilização dessas técnicas apenas para processos lentos.
- O estudo de estabilidade e robustez é mais complexo no caso de sistemas não lineares, que se constitui em uma área de grande interesse de pesquisadores.

De modo a tentar resolver essas dificuldades, uma grande variedade de diferentes técnicas e formulações surgiram ao longo dos últimos anos. Algumas delas são descritas de maneira sucinta aqui (CAMACHO & BORDONS, 2007).

- Extensões dos modelos lineares: Pode ser considerada uma das maneiras mais simples de lidar com as não linearidades do processo, sendo desenvolvida, originalmente para os controladores DMC. A ideia básica é adicionar um novo termo nas saídas das predições buscando levar em conta as não linearidades.
- Modelos locais: O conceito básico é promover sucessivas linearizações em torno de um ponto de operação, que permite soluções em tempo real, já que o problema a ser resolvido em todo instante de amostragem é uma programação quadrática. Extensões dessa ideia, utilizam uma linearização ao longo da trajetória de predição.

- NMPC subótimo: Essa aproximação evita a necessidade de achar o mínimo de uma função não convexa considerando o atendimento as restrições como o objetivo primário. Caso uma estratégia de otimização que obtenha soluções viáveis a cada período de amostragem seja utilizada e um decaimento da função custo é obtido, a otimização pode ser interrompida quando o tempo acaba e a estabilidade ainda pode ser garantida. A principal técnica que utiliza esse conceito foi proposta por Sckaert *et al.* (1999).
- Utilização de horizontes curtos: É evidente que horizonte curtos são preferidos do ponto de vista computacional, porém horizontes mais longos são requeridos para atingir a estabilidade e o desempenho desejado em malha fechada. Algumas aproximações tem sido propostas para tentar contornar esse problema. Zheng & Zhang (2001) apresentam um algoritmo cuja ideia chave é calcular exatamente a primeira ação de controle que é prontamente implementada, e aproximar as ações subsequentes, que não são implementadas. Dessa forma, tem-se apenas uma variável de decisão (ou o número de entradas no caso MIMO).
- Decomposição da sequência de controle: Uma das ideias básicas dos modelos lineares de MPC é a utilização dos conceitos de respostas livres e forçadas. Apesar de não se aplicar a sistemas não lineares, devido ao princípio da superposição, variações dessa ideia podem ser utilizadas para implementação de NMPCs. Camacho *et al.* (1997) propuseram um algoritmo onde as previsões são compostas pelas adição a resposta livre (respostas futuras com as variáveis manipuladas mantidas constantes), obtida de um modelo não linear, e a resposta forçada (resposta devido as ações de controle futuras), obtida através de um modelo linear de incrementos.
- MPC baseados em modelos de Volterra: Em alguns casos, o problema não linear apresenta uma estrutura especial que pode ser explorada para atingir soluções viáveis em tempo real. Caso o processo seja descrito por uma modelo de Volterra, soluções eficientes podem ser obtidas, especialmente em modelos de segunda ordem.

- Modelos de Hammerstein e Wiener: Caso o processo possa ser modelado por um modelo de Hammerstein, o problema pode ser facilmente transformado em linear invertendo a parte não linear. Dessa forma a solução pode ser obtida minimizando uma função custo que depende de uma variável intermediária. A mesma ideia é aplicada aos modelos de Wiener onde a não linearidade estática persegue a dinâmica linear. Aplicações desses modelos podem ser encontradas na literatura (NORQUAY *et al.* 1999); DOS SANTOS, 2007).
- Redes neurais: As redes neurais artificiais podem “apreender” o comportamento de um sistema não linear, a partir de dados de entrada e saída, e calcular os sinais de controle. Essa técnica tem sido aplicada em diversos processos industriais e em sistemas com intervalos de amostragem pequenos (DE NICOLAO *et al.*, 2000). No item 2.4.1 foi dada maior atenção a esses modelos, objeto de estudo dessa dissertação.
- Modelos em espaço de estado: Os modelos de espaço de estados lineares podem ser naturalmente estendidos para incluir as dinâmicas não lineares do processo. A utilização destes modelo para predição necessita que o estado esteja acessível através de medições ou inclusão de um estimador de estados.

Além dos modelos empíricos (ou semi-empíricos) construídos a partir de dados de entrada e saída da planta, os modelos fenomenológicos desenvolvidos a partir dos balanços de massa, energia e momento do processo também podem ser utilizados. Nesse caso, as predições são realizadas a partir da resolução das equações diferenciais que descrevem a dinâmica do processo. Para processos industriais complexos, esse tipo de modelo é extremamente difícil de se obter, exigindo grande conhecimento do processo (CAMACHO & BORDONS, 2007).

2.4.1 Redes Neurais

2.4.1.1 Conceito e Considerações Gerais

As redes neurais artificiais (ANN) têm sido cada vez mais utilizadas nas mais diversas áreas de aplicações da engenharia. Segundo Haykin (2001), uma ANN é

um processador paralelamente distribuído constituído por unidades de processamento simples, capaz de armazenar conhecimento experimental e torná-lo disponível para uso, que se assemelha ao cérebro humano em basicamente dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente por um processo de aprendizagem; forças de conexão entre os neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

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

A solução de problemas através de ANNs é bastante atrativa, já que a forma como estes são representados internamente pela rede e o paralelismo natural inerente à arquitetura das ANNs criam a possibilidade de um desempenho superior ao dos modelos convencionais. O procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem (as vezes também chamado de treinamento) em que um conjunto de exemplos é apresentado para a rede, a qual extrai as características necessárias para representar a informação fornecida (BRAGA *et al.*, 2000).

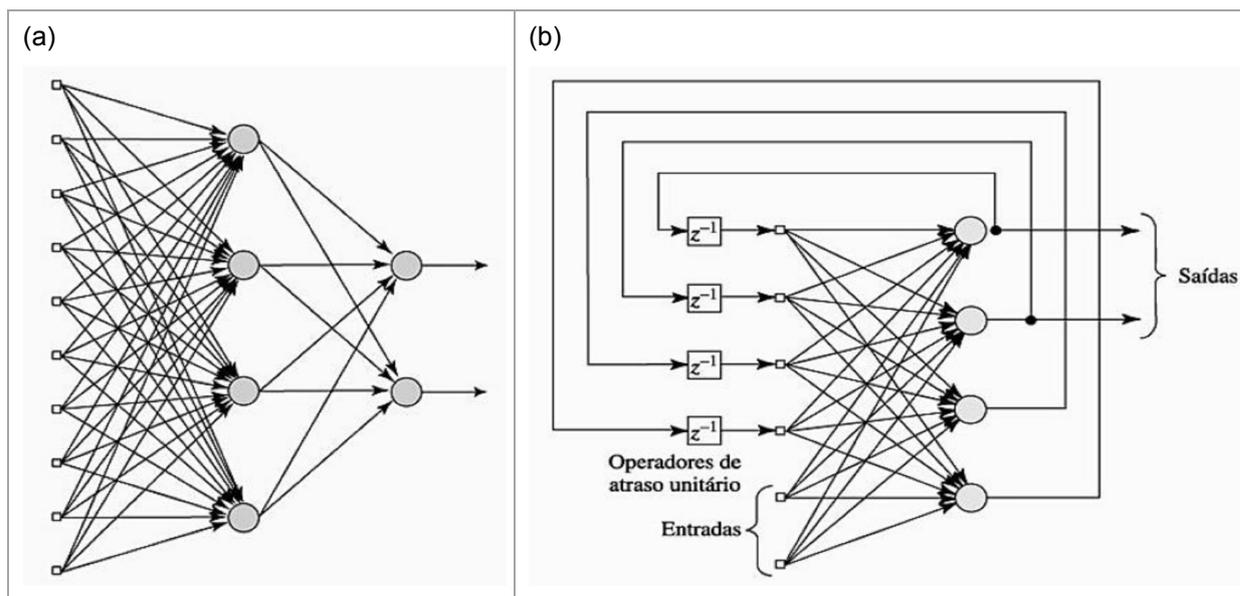
Segundo De Souza Jr. (1993), os métodos de treinamentos podem ser classificados em supervisionados e não supervisionados. Nos métodos supervisionados, há um “professor”, que “ensina” a rede o comportamento correto, ou seja, as redes são treinadas por experiência, tal que padrões com dados de entrada e saída são apresentados de modo que ela modifica as suas interconexões (pesos e *biases*) a fim de obterem as saídas desejadas. Já nos métodos não supervisionados, a rede é autônoma, ou seja, os dados são apresentados à rede, que descobre alguma propriedade sobre os mesmos e aprende como refletir estas propriedades nas suas saídas, sem ajuda de um “professor”. Os métodos mais utilizados para identificação e modelagem de processos são os supervisionados (PROTTES, 2009).

Segundo Haykin (2001), as ANNs apresentam algumas propriedades úteis à identificação e modelagem de processos:

- Não linearidade: extremamente importante para representação de processos não lineares;
- Mapeamento de entrada-saída: capacidade de aprender de maneira supervisionada. Os dados de entrada e saída são apresentados à rede, que é capaz de modificar seus parâmetros (pesos e biases) de modo a apresentar as saídas desejadas;
- Adaptabilidade: capacidade da rede se adaptar facilmente a novas condições. Uma rede treinada para operar em um ambiente específico pode ser facilmente retreinada para lidar com pequenas modificações nas condições operativas do ambiente, podendo, em alguns casos, inclusive ser projetada para modificar seus parâmetros em tempo real;
- Resposta a evidências: uma rede neuronal pode ser treinada para fornecer informação não somente sobre qual padrão particular selecionar, mas também sobre a confiança na decisão tomada;
- Tolerância a falhas: uma ANN tem o potencial de ser tolerante a falhas. Devido à natureza distribuída da informação armazenada, danos a um neurônio ou conexão geram uma degradação suave do desempenho em vez de apresentar uma falha catastrófica;

Segundo De Souza Jr. (1993), as redes podem ser classificadas, dependendo da sua topologia, em basicamente dois grupos:

- Feedforward: redes com propagação para frente, podendo ser monocamadas (apenas camada de entrada e saída, sendo os cálculos realizados apenas pela camada de saída) ou multicamadas (possuem camadas ocultas que realizam cálculos). Um exemplo de estrutura de uma rede *feedforward* é apresentado na Figura 4a;
- Recorrentes (Feedbacks): redes com propagação para trás, podendo ter laços de retroalimentação que se originam tanto de neurônios ocultos como neurônios da camada de saída. Um exemplo de estrutura de uma rede recorrente é apresentado na Figura 4b



Fonte: HAYKIN (2001) - Adaptado

Figura 4 – Arquitetura genérica de ANN (a) Feedforward (b) Recorrentes.

As redes devem ter boa capacidade de generalização, ou seja, uma rede devidamente treinada deve responder de forma coerente a padrões desconhecidos. Um dos maiores desafios no estudo da capacidade de generalização de uma ANN é a escolha da arquitetura apropriada do modelo neuronal em relação à complexidade do problema. Arquiteturas grandes elevam a complexidade do modelo. Quando esta complexidade é maior do que o necessário para a modelagem do problema, há um superajuste, ou *overfitting*, da rede aos dados de treinamento, o que resulta em respostas não adequadas. Por outro lado, se a complexidade do problema supera a complexidade do modelo neuronal, ocorre o fenômeno de subajuste ou *underfitting* (PROTTES, 2009).

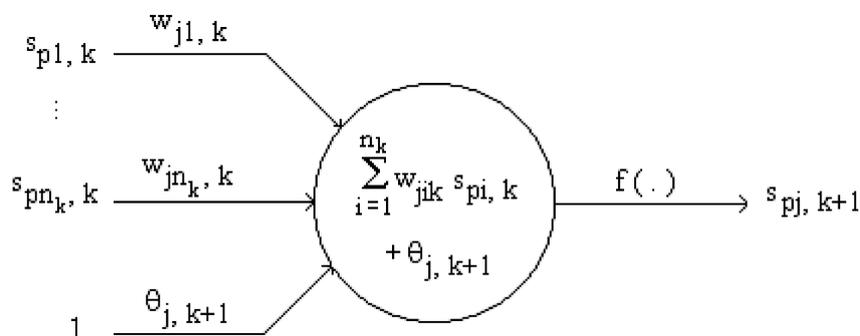
Para avaliar e garantir uma boa generalização, o grupo de dados disponíveis deve ser dividido basicamente em três grupos de dados: treinamento, teste e validação. O primeiro é utilizado para o ajustes dos parâmetros da rede durante o treinamento, o segundo grupo é utilizado para testes das redes. Já o terceiro grupo, é utilizado para seleção final de modo a garantir uma boa capacidade de generalização da rede.

Existem diversos tipos de redes neurais, dentre as quais vale destacar:

- Redes *Perceptrons* Multicamadas (MLP):
- Redes de Base Radial (RBF):

2.4.1.2 Redes Perceptron Multicamadas (MLP)

As redes MLPs são redes *feedforward* que possuem uma camada de entrada, uma ou mais camadas escondidas, e uma camada de saída, e originalmente, eram treinadas por um método supervisionado muito popular, o *backpropagation*, baseado na aprendizagem pela correção do erro (HAYKIN, 2001). Posteriormente, outros métodos de otimização, como o método dos gradientes conjugados, também passaram ser utilizados para determinação de seus parâmetros. A Figura 5 apresenta o modelo de um neurônio das redes MLP.



Fonte: DE SOUZA JR. (1993)

Figura 5 – Modelo de um neurônio artificial.

A partir do modelo apresentado, podem ser identificados alguns elementos:

- Sinais de entrada ($s_{pi,k}$, $i = 1, \dots, n_k$);
- Conjunto de sinapses que são caracterizadas cada um por um peso ($w_{ji,k}$, $i = 1, \dots, n_k$);
- O bias ($\theta_{j,k+1}$) que aumenta ou diminui a entrada líquida da função de ativação, dependendo da convenção do modelo;
- Função de ativação ($f(\cdot)$) que limita a amplitude do sinal de cada neurônio;
- Sinal de saída ($s_{pi,k+1}$, $i = 1, \dots, n_k$).

Um neurônio qualquer “ j ” da camada ($k+1$) recebe um conjunto de informações $s_{pi,k}$ ($i = 1, \dots, n_k$), correspondentes às saídas (ou ativações) dos neurônios n_k da camada anterior (ponderadas, cada uma, pelo peso $w_{ji,k}$

correspondente a sua conexão). O neurônio soma essas entradas ponderadas e o valor resultante é somado a um limite interno de ativação, o *bias* ($\theta_{j,k+1}$). O neurônio “*j*” gera uma resposta ($s_{pj,k+1}$) de acordo com a função de ativação (DE SOUZA JR., 1993). O cálculo do sinal de saída é expresso pela seguinte equação:

$$s_{pj,k+1} = f\left(\left[\sum_{i=1}^{n_k} w_{jik} s_{pi,k}\right] + \theta_{j,k+1}\right) \quad (33)$$

As funções de ativações limitam a amplitude da saída do neurônio, e deve ser definida de acordo com as peculiaridades e adaptabilidade de cada sistema. A Tabela 2 apresenta uma compilação dos principais tipos de função de ativação (MONTANHEIRO, 2004).

Tabela 2 – Funções de ativação normalmente utilizadas.

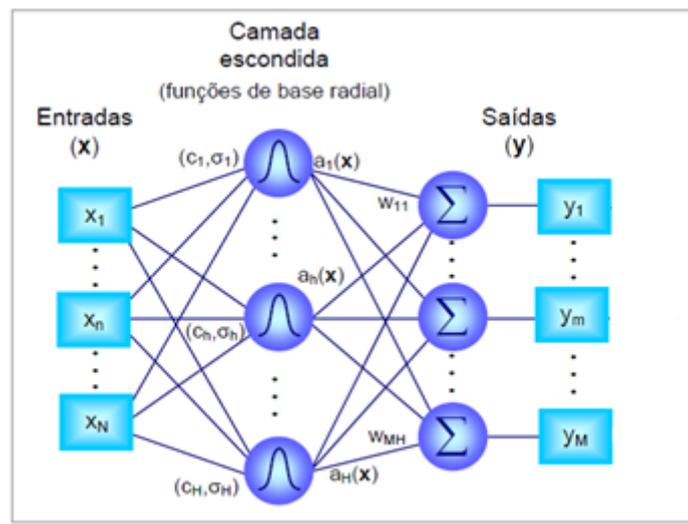
Tipo	Descrição (f(x)=)	Saídas
Identidade	x	(-inf; +inf)
Sigmoidal	$\frac{1}{1 + e^{-x}}$	(0; +1)
Hiperbólica	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$	(-1; +1)
Exponencial	e^{-x}	(0; +inf)
Senóide	$sen(x)$	[-1; +1]
Rampa	$\begin{cases} x \leq -1 \rightarrow -1 \\ -1 \leq x \leq +1 \rightarrow x \\ x \geq +1 \rightarrow +1 \end{cases}$	[-1; +1]
Degrau	$\begin{cases} x < 0 \rightarrow 0 \\ x \geq 0 \rightarrow +1 \end{cases}$	[0; +1]

Fonte: Montanheiro (2004) - Adaptado

O algoritmo de aprendizagem utilizado, o *backpropagation*, consiste basicamente em dois passos: um passo para frente, a propagação, onde um padrão de dados de entrada é passado a rede e se propaga através da rede, camada por camada, gerando um conjunto de saídas, com os parâmetros da rede (pesos e biases) sendo mantidos fixos; e um passo para trás, onde os parâmetros da rede são reajustados através de um sinal de erro obtido entre as saídas da rede e os dados reais (RUMELHART & McCLELLAND, 1986).

2.4.1.3 Redes de Base Radial (RBF)

As redes RBFs possuem basicamente três camadas conforme mostrado na Figura 6. As camadas de entrada e de saída são lineares. Na camada escondida, os neurônios possuem função de ativação radial, a função Gaussiana (Equação 34), que possui um valor máximo em seu centro, e decresce com o aumento da distância verificada em relação ao centro. Cada neurônio da camada escondida possui uma região finita de ativação, que é determinada pela distância Euclidiana verificada entre o vetor de entradas (x) e o centro (c_h), ponderadas por um fator de escala (σ_h).



Fonte: DE SOUZA JR. (2010)

Figura 6 – Representação esquemática de uma rede do tipo radial (RBF).

$$a_h(x) = \exp\left(\frac{-\|x - c_h\|^2}{\sigma_h^2}\right) \quad (34)$$

As saídas de cada neurônio da camada escondida são conectadas aos neurônios da camada de saída através de pesos associados. A saída de cada neurônio da camada de saída é então calculada conforme Equação 35.

$$y_m(x) = \sum_{h=1}^H w_{mh} a_h(x) \quad m = 1, \dots, N \quad (35)$$

Para redes de classificação, a partir dos sinais dos neurônios da camada de saída, avalia-se qual neurônio é o vencedor, ou seja, em qual N grupos (ou padrões) se classificam os dados pertencentes ao vetor de entradas.

Para o treinamento das redes do tipo RBF, são necessárias duas etapas: a etapa de determinação dos centros (c) e dos fatores de escala (σ). Os centros podem ser determinados através do algoritmo *K-means*. Após o ajuste dos centros, os fatores de escala são ajustados pela heurística dos P vizinhos mais próximos (*P-Nearest Neighbor*). Após a determinação desses dois vetores, os valores da matriz de pesos (W) são definidos utilizando-se a técnica de regressão linear (mínimos quadrados) (DE SOUZA JR., 2010).

As redes RBFs são normalmente utilizadas em problemas de classificação, e se comparadas com as redes MLPs, requerem uma quantidade superior de parâmetros, porém necessitam de um menor tempo para treinamento (HIMMEBLAU, 2000).

2.4.1.4 Identificação e Controle de Processos

Devido às características não lineares inerentes ao mapeamento entre as suas camadas, as ANNs se caracterizam como ferramentas bastante apropriadas para modelagem e controle de processos (BRAGA *et al.*, 2000). Além disso, a utilização de redes neurais possibilita o controle de sistemas que apresentam grandes incertezas no modelo, desde que se conheçam dados de entrada e saída do mesmo, que são utilizados para o treinamento das redes, característica essa bem atrativa aos engenheiros de controle, para quem a incerteza de modelos é uma dificuldade sempre presente (DE SOUZA JR., 1993).

Segundo Agarwal (1997), as estratégias de controle baseadas em redes neuronais podem ser agrupadas em duas categorias:

- Controle direto: a ANN como próprio controlador, sendo os parâmetros do mesmo estimados diretamente pela rede;
- Controle indireto: a ANN como modelo do processo, onde os parâmetros do controlador não são estimados diretamente, mas sim indiretamente,

onde a rede funciona como um modelo de previsão de estados ou dinâmicas futuras.

No controle direto, a saída alvo da rede corresponde à entrada do processo, portanto, a rede age como inversa do processo, produzindo um sinal de entrada que leva a saída do processo para o *setpoint* desejado. A Figura 7 apresenta a estrutura básica do controle direto.

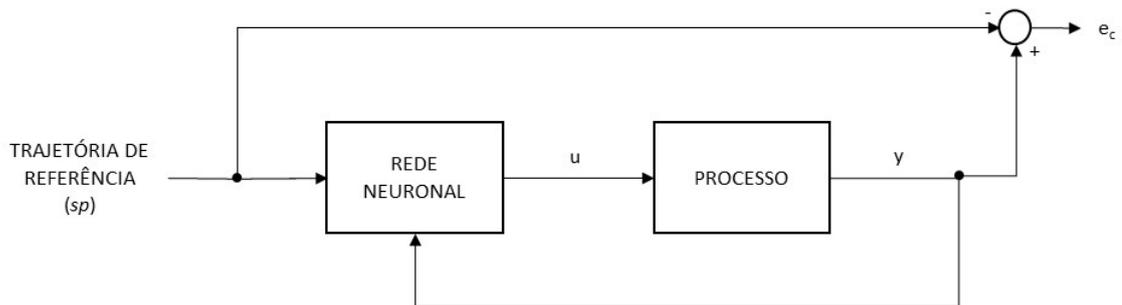


Figura 7 – Modelo básico de controle direto.

Conforme identificado por Psychogios & Ungar (1991) e reportado por De Souza Jr. (1993), o controlador direto é significativamente afetado pelo erro envolvido no treinamento da rede para aprender a dinâmica inversa. Os trabalhos de controle direto são mais comuns na área de robótica (DE SOUZA JR., 1993).

No controle indireto, a rede é posta paralelamente ao processo e treinada de modo a ser capaz de prever as saídas do processo. Essas saídas são utilizadas indiretamente pelo controlador para ajuste dos seus parâmetros de modo a aproximar o processo do *setpoint* desejado. A Figura 8 apresenta a estrutura básica do controle indireto.

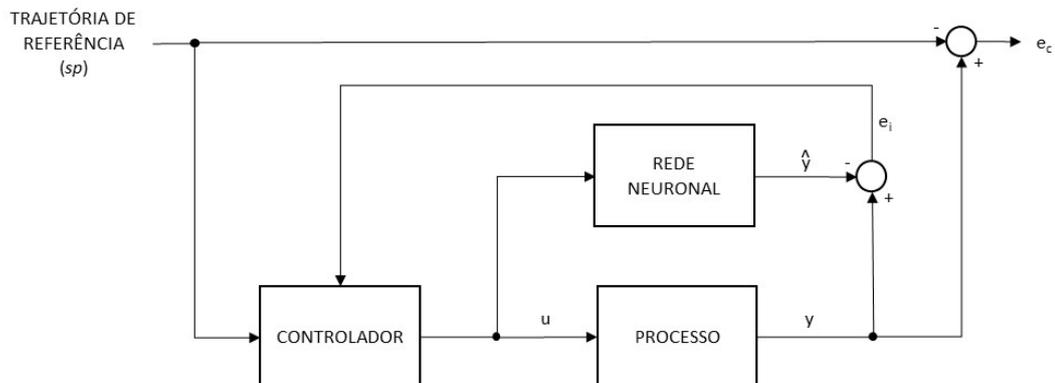


Figura 8 – Modelo básico de controle indireto.

O controle preditivo baseado em redes neurais pode ser classificado como um exemplo de controle indireto (DE SOUZA JR., 1993). A ANN é utilizada para prever saídas futuras e um procedimento de otimização é aplicado para calcular as ações de controle futuras de modo a minimizar os erros entre as saídas previstas e uma trajetória de referência (*setpoint*), função custo apresentada anteriormente na Equação 1.

A estrutura geral do controlador segue modelo geral de controle preditivo apresentado anteriormente na Figura 2. A Figura 9 apresenta a mesma estrutura já aplicada a um modelo de rede neuronal.

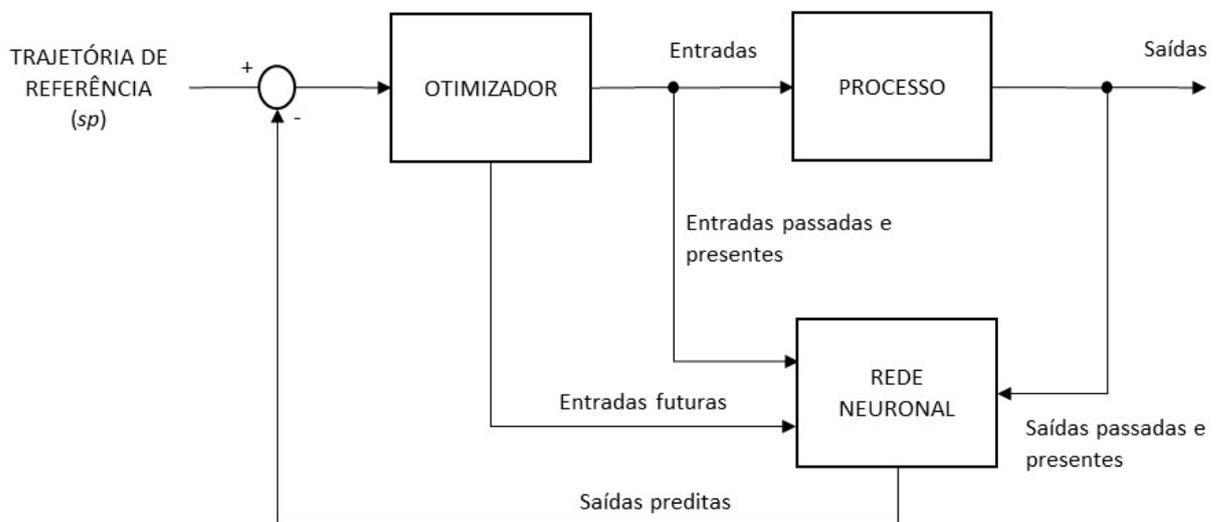


Figura 9 – Estrutura geral de um controlador preditivo baseado em redes neurais.

A qualidade do controlador preditivo baseado em redes neurais está diretamente ligada à capacidade da rede de representar a dinâmica dos sistemas. Segundo Schnitman (1998), em geral, a capacidade de modelar sistemas dinâmicos se dá pela utilização de dados atrasados no tempo, ou seja, uma ANN cujas entradas são compostas por valores passados das próprias variáveis de entrada e das variáveis de saída (também conhecida como TDNN, *Time Delay Neural Network*). A Figura 10 apresenta a estrutura geral de uma rede que recebe dados atrasados.

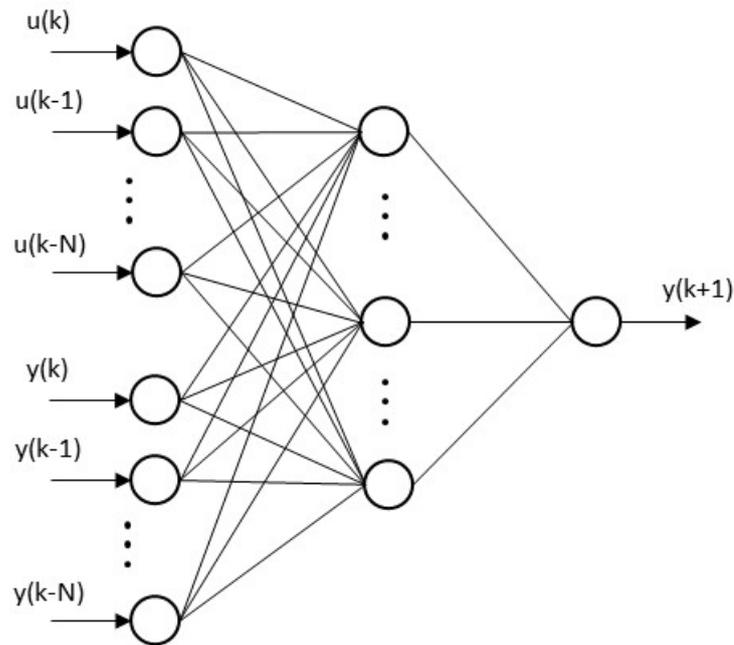


Figura 10 – Exemplo de rede que recebe dados atrasados no tempo.

Segundo De Souza Jr. (1993), duas arquiteturas diferentes podem ser utilizadas para predição ao longo de um horizonte. Na primeira, a rede fornece diretamente como saída as P predições no futuro. Na segunda, a rede é treinada para prever apenas um passo adiante, que é realimentado a rede como entrada para o cálculo da próxima predição, os outros dados de entrada da rede são deslocados para trás e isto é feito iterativamente até P predições tenham sido obtidas.

De Souza Jr. (1993) ainda resumiu algumas desvantagens das redes do primeiro tipo em comparação com as do segundo tipo, a partir de teste realizados pelo próprio autor e outros encontrados na literatura:

- Sua arquitetura produz redes maiores;
- São menos flexíveis, já que caso deseje-se aumentar o horizonte de predição, as redes do primeiro tipo exigiriam um novo treinamento, enquanto as do segundo tipo, precisariam apenas aumentar o número de iterações realizadas;
- Em horizontes de predição típicos para utilização em MPCs, a predição de P passos diretamente envolve um erro maior, que a predição de apenas um passo no futuro, característica das redes do segundo tipo.

3 MODELO DO PROCESSO

Conforme apresentado no Capítulo 1, o processo escolhido para análise de controladores preditivos não lineares foi a reação com cinética introduzida por Vusse (1964), que ficou conhecida como a reação de Van de Vusse. Este modelo é bastante conhecido e estudado na literatura devido às características de não linearidades.

3.1 Descrição e Modelagem

Na reação de Van de Vusse, ciclopentenol (B) é produzido a partir do ciclopentadieno, com formação também dos subprodutos ciclopentanadiol (C) e dicitlopentadieno (D), conforme as seguintes reações (VUSSE, 1964):



Conforme descrito em mais detalhes por Engell & Klatt (1993), a reação ocorre em um reator CSTR, conforme Figura 11, provido de uma camisa de resfriamento para manutenção da temperatura do mesmo, já que a reação é exotérmica.

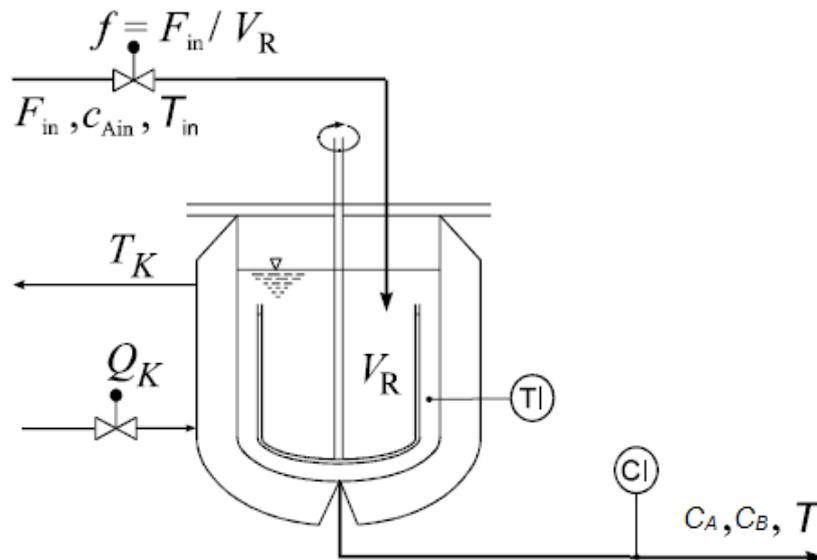


Figura 11 – Representação esquemática do reator de CSTR com reação de Van de Vusse.

Considerando a densidade constante ao longo do reator e o controle de nível ideal, para simplificação, a dinâmica do sistema é descrita pelas seguintes equações diferenciais, resultantes dos balanços de massa e energia do reator e da camisa de resfriamento (ENGELL & KLATT, 1993).

$$\frac{dC_A}{dt} = \frac{F_{in}}{V_R} \cdot [C_{Ain} - C_A] - k_1(T)C_A - k_3(T)C_A^2 \quad (38)$$

$$\frac{dC_B}{dt} = -\frac{F_{in}}{V_R} \cdot C_B + k_1(T)C_A - k_2(T)C_B \quad (39)$$

$$\frac{dT}{dt} = \frac{F_{in}}{V_R} [T_{in} - T] + \frac{k_w A_R}{\rho C_p V_R} [T_k - T] + \quad (40)$$

$$- \frac{1}{\rho C_p} [k_1(T)C_A \Delta H_1 + k_2(T)C_B \Delta H_2 + k_3(T)C_A^2 \Delta H_3]$$

$$\frac{dT_k}{dt} = \frac{Q_k}{m_k C_{p_k}} + \frac{k_w A_R}{m_k C_{p_k}} [T - T_k] \quad (41)$$

Engell & Klatt (1993) também apresentaram parâmetros cinéticos da reação e propriedades do reator/camisa, que são mostradas nas Tabelas 3 e 4. Esses dados foram utilizados em diversos outros estudos sobre esse sistema (SECCHI *et. al.*, 2001; TRIERWEILER, 1997; DURAIKI, 2001).

Tabela 3 – Parâmetros cinéticos da reação.

Reação	$k_i = k_{i0} \exp(E_i/T)$			Entalpia de Reação ΔH_i (kJ/mol)
	k_{i0}	Unidade k_{i0}	Energia de Ativação E_i (K)	
$A \xrightarrow{k_1} B$	$1,287 \times 10^{12}$	h^{-1}	-9758,3	4,2
$B \xrightarrow{k_2} C$	$1,287 \times 10^{12}$	h^{-1}	-9758,3	-11,0
$2A \xrightarrow{k_3} D$	$9,043 \times 10^9$	$l/(mol.h)$	-8560	-41,85

Fonte: ENGELL & KLATT (1993)

Tabela 4 – Propriedades físico-químicas e dimensões do reator.

Parâmetro	Valor	Unidade
ρ	0,9342	kg/l
C_p	3,01	kJ/(kg.K)
k_w	4032	kJ/(m ² .h.K)
A_R	0,215	m ²
V_R	10	l
m_k	5,0	kg
C_{p_k}	2,0	kJ/(kg.K)

Fonte: ENGELL & KLATT (1993)

Alguns autores fizeram uso de algumas simplificações no modelo para estudos de diversos controladores:

- A primeira simplificação é a consideração da temperatura da camisa como variável manipulada, ao invés do calor retirado, que elimina a equação do balanço de energia na camisa de resfriamento, Equação 6 (VOJTESEK & DOSTAL, 2010, MONTANHEIRO, 2004);
- Outra simplificação é a consideração do controle ideal de temperatura, reduzindo o sistema para a condição isotérmica, e conseqüentemente eliminando a equação de balanço de energia no reator, Equação 5 (ANURADHA *et al.*, 2009; SECCHI *et al.*, 2001; DURASKI, 2001).

3.2 Comportamento do Processo

O comportamento do processo em estado estacionário foi estudado em função da razão de alimentação (F_{in}/V_R). A temperatura (T_{in}) na corrente de alimentação foi fixada em 130°C. As simulações foram feitas utilizando três valores da concentração de A (C_{Ain}), 4,0, 5,1 e 6,0 mol/l. Para o calor retirado do reator pela camisa de resfriamento (Q_k) foi utilizado o valor de -4250 kJ/h. O resultado obtido para a concentração de B (C_B) e temperatura do reator (T) são apresentados nas Figuras 12 e 13, respectivamente.

Conforme pode ser observado na Figura 12, a concentração de B sofre comportamento bastante antagônico para diferentes razões de alimentação. Para razões baixas (20 – 60 h⁻¹) tem-se um ganho positivo da razão em relação à concentração de B, ou seja, aumentando-se a vazão, aumenta-se a concentração de B. Já para razões altas (acima de 70 h⁻¹) o efeito é contrário, um aumento de vazão implica numa redução da concentração de B, indicando um ganho negativo. A mesma característica de inversão de ganho também pode ser observada na temperatura do reator, embora de forma mais suave. Em razões muito baixas (menores que 10 h⁻¹), o sistema sofre outra alteração de ganho, sendo a concentração de B reduzida com o aumento da razão de alimentação.

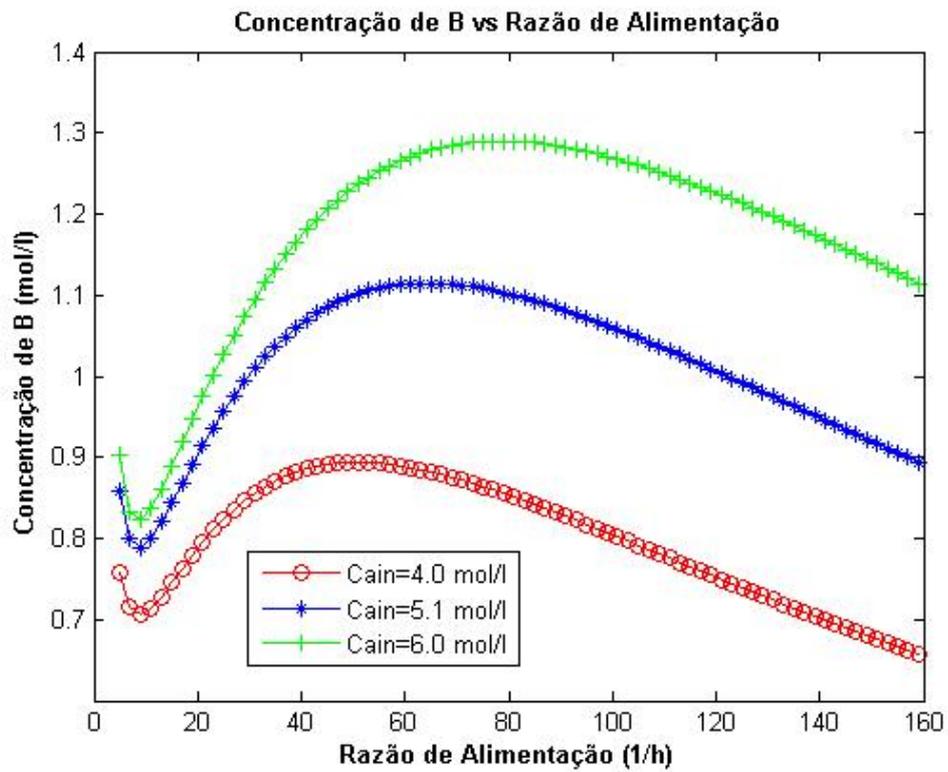


Figura 12 – Concentração no estado estacionário de B em função da razão de alimentação.

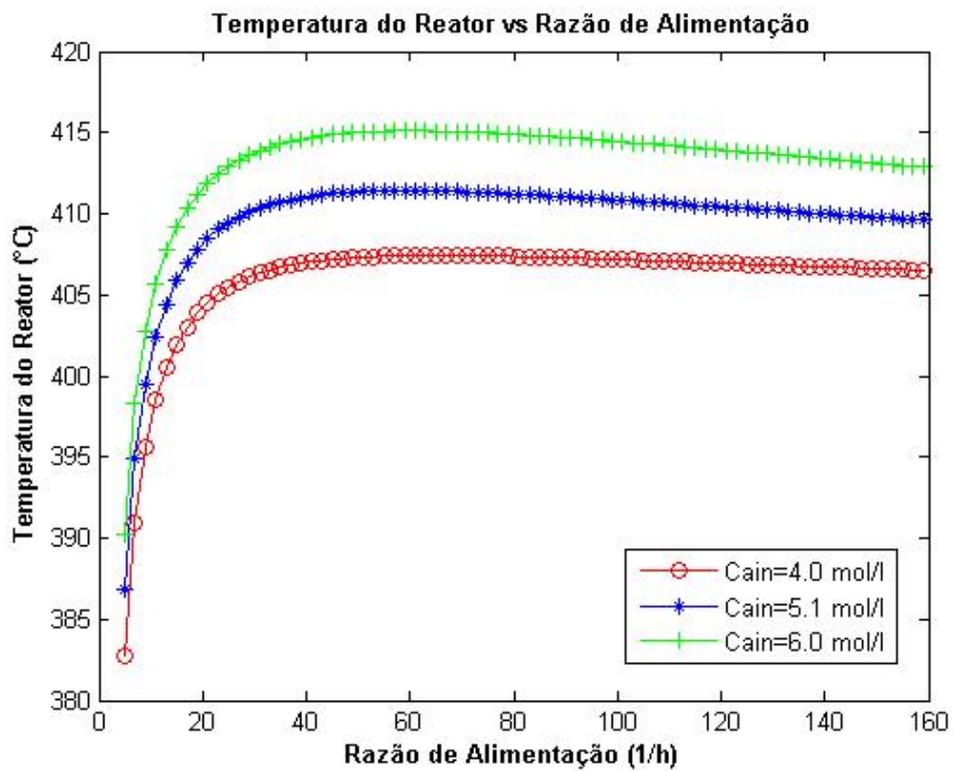
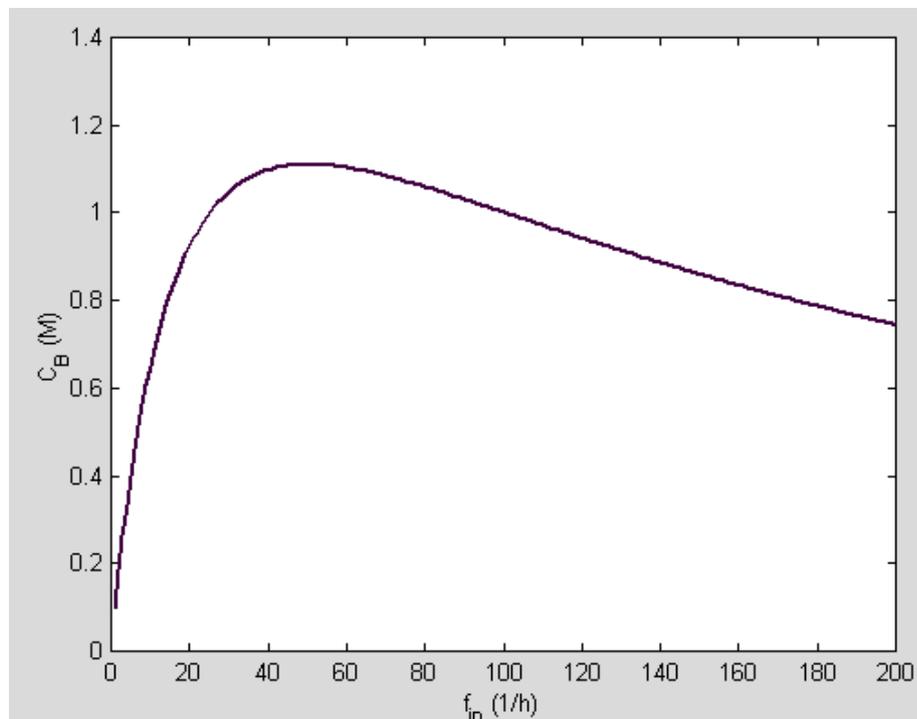


Figura 13 – Temperatura do reator no estado estacionário em função da razão de alimentação.

Outro comportamento que chama a atenção na Figura 12, é o fato de diferentes valores da razão de alimentação levarem o processo ao mesmo estado estacionário, mesmo valor de C_B . Este fenômeno, conhecido na literatura como multiplicidade de entradas, conforme observado por Montanheiro (2004) é extremamente prejudicial ao controle do processo. Pequenas perturbações de origens diversas podem levar o sistema a um novo estado indesejável, dependendo do tipo de controlador empregado, e em alguns casos, pode até produzir oscilações entre dois estados estacionários.

As simplificações utilizadas por alguns autores em seus estudos, conforme apresentadas anteriormente, resultam em pequenas diferenças no comportamento do sistema no estado estacionário.

A Figura 14 apresenta a mesma análise de comportamento do sistema em estado estacionário feita por Duraski (2001). Conforme pode ser observado, a primeira inversão de ganho em vazões baixas não aparece. Esse mesmo comportamento foi identificado por Secchi *et al.* (2001).



Fonte: DURASKI (2001)

Figura 14 – Concentração no estado estacionário de B em função da razão de alimentação para o modelo isotérmico.

A Figura 15 apresenta o parâmetro de ganho relativo (parâmetro λ da matriz RGA) calculado, considerando $C_{Ain} = 5,1 \text{ mol/l}$, para diferentes razões de alimentação, onde é possível identificar a forte interação entre as variáveis envolvidas, principalmente na região de máxima concentração de C_B .

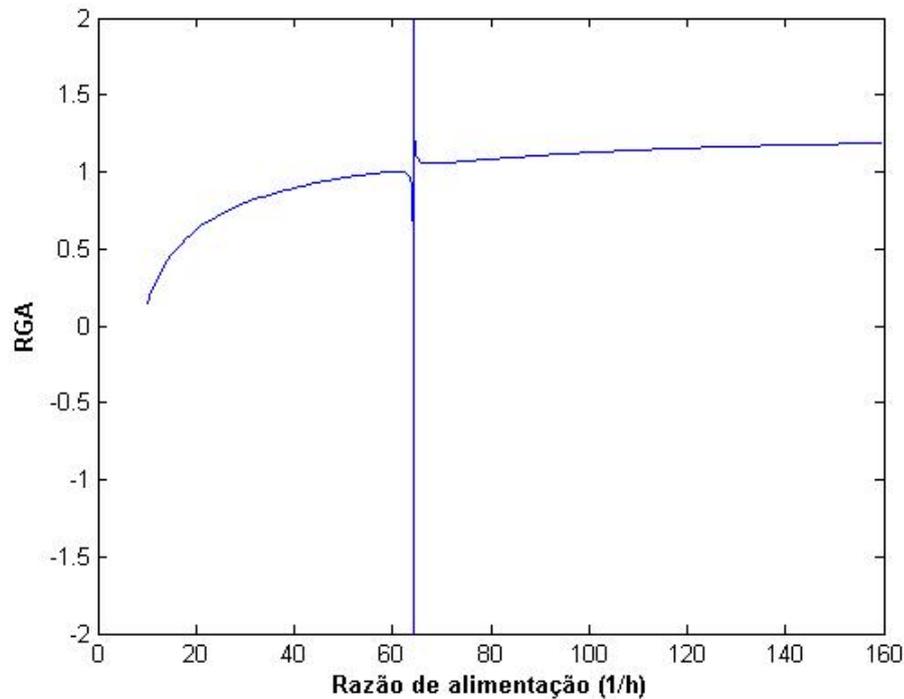


Figura 15 – RGA do processo em função da razão de alimentação.

3.3 Seleção da Região de Estudo

Analisando o comportamento da concentração de B, Figura 12, nota-se que o ponto ideal de operação seria em torno do ponto de máxima concentração de C_B , por ser possível obter um produto com maior concentração do produto desejado, componente B. Esta região também é a mais desafiadora do ponto de vista de controle, por apresentar inversão de ganho e forte interação entre as variáveis do processo.

Nesta dissertação, portanto, foi escolhida como região de estudo, o ponto com razão de alimentação de 60 h^{-1} , considerando a concentração inicial de A em $5,1 \text{ mol/l}$. O objetivo será projetar controladores que sejam capazes de manter o processo operando de maneira estável em torno do ponto de máxima concentração de B, obedecendo às restrições de operação do mesmo.

3.4 Linearização do Modelo

Para possibilitar os testes com os controladores PID tradicionais, a serem utilizado como referência, o processo também foi descrito por modelo linear em espaço de estados em torno do ponto de operação utilizado (60 h^{-1}).

$$\begin{aligned}\dot{\mathbf{x}} &= \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \\ \mathbf{y} &= \mathbf{C}\mathbf{x} + \mathbf{D}\mathbf{u}\end{aligned}\quad (42)$$

Em que:

$$\dot{\mathbf{x}} = \begin{bmatrix} dC_A/dt \\ dC_B/dt \\ dT/dt \\ dT_k/dt \end{bmatrix}; \quad \mathbf{x} = \begin{bmatrix} C_A \\ C_B \\ T \\ T_k \end{bmatrix}; \quad \mathbf{u} = \begin{bmatrix} F_{in} \\ Q_k \end{bmatrix}; \quad \mathbf{y} = \begin{bmatrix} C_A \\ C_B \\ T \\ T_k \end{bmatrix}$$

$$\mathbf{A} = \begin{bmatrix} -160,1265 & 0 & -9,9270 & 0 \\ 64,3279 & -124,3279 & 3,8508 & 0 \\ 436,7074 & 251,6434 & -57,6098 & 30,8285 \\ 0 & 0 & 86,6880 & -86,6800 \end{bmatrix}; \quad \mathbf{B} = \begin{bmatrix} 0,2949 & 0 \\ -0,1113 & 0 \\ -0,8257 & 0 \\ 0 & 0,100 \end{bmatrix}$$

$$\mathbf{C} = \mathbf{I}; \quad \mathbf{D} = \mathbf{0}$$

Considerando as variáveis manipuladas, F_{in} e Q_k , e as saídas do processo desejadas, C_B e T , pode-se obter as funções de transferência em torno do ponto de operação (60 h^{-1}).

$$G_1(s) = \frac{C_B(s)}{F_{in}(s)} = \frac{-0,1113s^3 - 18,1s^2 - 337,9s + 5373}{s^4 + 428,8s^3 + 6,664x10^4 s^2 + 4,369x10^6 s + 9,342x10^7} \quad (43)$$

$$G_2(s) = \frac{T(s)}{F_{in}(s)} = \frac{-0,8257s^3 - 205,7s^2 - 1,177x10^4 s - 1,228x10^4}{s^4 + 428,8s^3 + 6,664x10^4 s^2 + 4,369x10^6 s + 9,342x10^7} \quad (44)$$

$$G_3(s) = \frac{C_B(s)}{Q_k(s)} = \frac{-2,274x10^{-13} s^3 - 5,821x10^{-11} s^2 + 11,87s - 67,72}{s^4 + 428,8s^3 + 6,664x10^4 s^2 + 4,369x10^6 s + 9,342x10^7} \quad (45)$$

$$G_4(s) = \frac{T(s)}{Q_k(s)} = \frac{-2,274x10^{-13} s^3 + 3,083s^2 + 876,9s + 6,137x10^4}{s^4 + 428,8s^3 + 6,664x10^4 s^2 + 4,369x10^6 s + 9,342x10^7} \quad (46)$$

3.5 Aplicações de Controle ao Modelo na Literatura

Devido às suas características não lineares, conforme apresentadas no item anterior, o reator com cinética de Van de Vusse vem sendo frequentemente empregado no estudo de diversas técnicas de controle desde a década de 90.

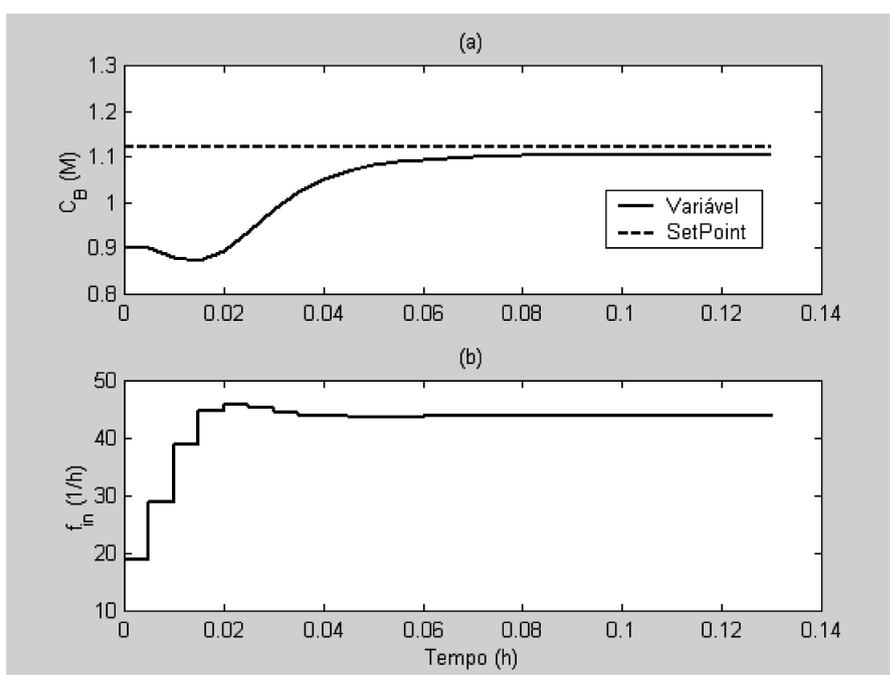
Engell & Klatt (1993) investigaram a utilização de um controle não linear baseado num método robusto de controle linear (Método da resposta em frequência), utilizando variação no ganho do controlador em função da vazão de alimentação (*gain scheduling*). Os resultados dos controladores foram bons, porém eles foram elaborados e testados para um faixa restrita de operação ($5 \text{ h}^{-1} \leq F_{in}/V_R \leq 35 \text{ h}^{-1}$), compreendendo apenas o primeiro ponto de inversão de ganho em baixas vazões. Além disso, como informado pelos próprios autores, este método pode tornar-se instável em certas condições, sendo necessária a garantia de variações suaves na variável que reprogramará o ganho.

Secchi *et al.* (2001) propuseram uma comparação entre a utilização de diversos tipos de MPC (linear adaptativo, redes de modelos locais, modelo linearizado num determinado ponto de operação e modelo não linear) utilizando o modelo de Van de Vusse, considerando a aproximação para o reator isotérmico (Caso SISO). No primeiro grupo de teste, sem considerar zonas de inversão de ganho, todos os controladores tiveram desempenho satisfatório. No segundo grupo de testes, considerando zonas de inversão de ganho, foi necessário aumentar o horizonte de predição em 5x para obter resultados razoáveis, exceto para o modelo linear que não funcionou nem para horizontes de predições elevados. Os autores observaram também que o tempo de amostragem representa um ponto crucial para bom funcionamento dos controladores, podendo levar o mesmo sistema a respostas insatisfatórias.

Duraiski (2001) desenvolveu um algoritmo MPC não linear utilizando linearizações ao longo da trajetória (LLT), onde o modelo de Van de Vusse (Caso SISO) foi utilizado para testes. O autor mostrou a ineficácia dos controlares preditivos lineares convencionais para controle em processos com inversão de

ganho. O algoritmo LLT, cuja sistemática foi proposta por Trierweiler & Secchi (2000), consiste num método capaz de minimizar a função objetivo utilizando um modelo totalmente não linear, através de sucessivas linearizações que alavancam a convergência do modelo.

Conforme pode ser observado na Figura 16, o algoritmo LLT proposto por Duraski (2001), durante uma simulação de mudança de *setpoint* 0,9 mol/l para 1,12 mol/l, consegue levar e manter o sistema na máxima concentração que pode ser atingida no estado estacionário (1,11 mol/l). A mesma simulação foi feita considerando um distúrbio na constante da Reação 2 (+10% em k_2), e o mesmo resultado satisfatório foi encontrado.

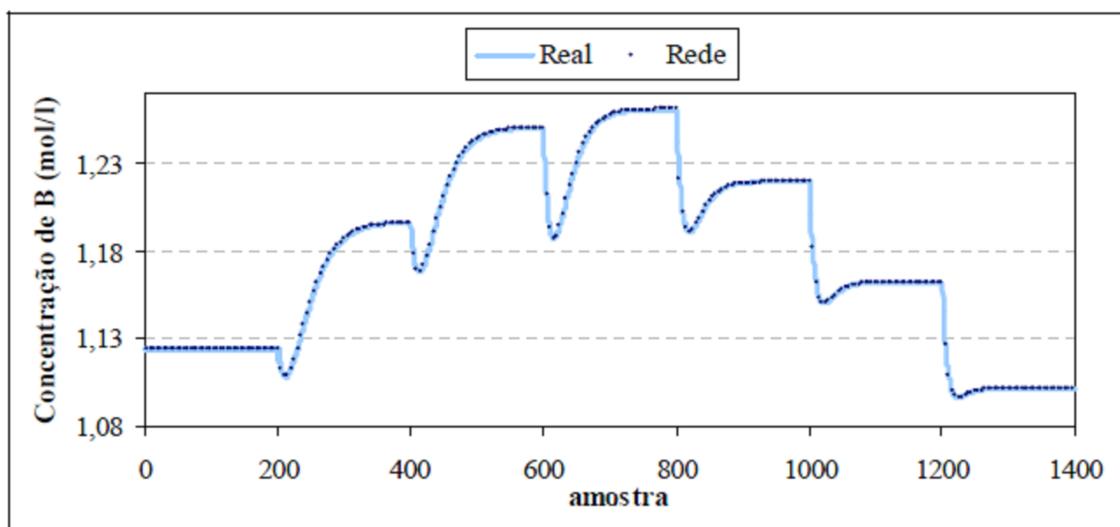


Fonte: DURASKI (2001)

Figura 16 – Simulação da atuação do controlador LLT na mudança de *setpoint* no reator de Van de Vusse. (a) Resposta na saída do sistema (b) respectivas ações de controle tomadas.

Claumann (2003) avaliou a utilização de redes neurais *wavelets*, que segundo o próprio autor podem ser consideradas basicamente redes de função de base radial, para predições do comportamento do sistema, sendo considerada a aproximação para o reator isotérmico (SISO). Para avaliar o desempenho em malha aberta, foi gerado um grupo de dados de teste, sendo que as perturbações aplicadas na taxa de diluição foram pulsos crescentes entre 30 e 180 h^{-1} com largura de 200 intervalos de amostragem, onde a rede foi utilizada como um simulador, ou seja, os dados de entrada eram os próprios dados preditos pela rede nos instantes

anteriores. Conforme observado por Claumann (2003), a rede conseguiu identificar perfeitamente o comportamento não linear de resposta inversa.



Fonte: CLAUMANN (2003)

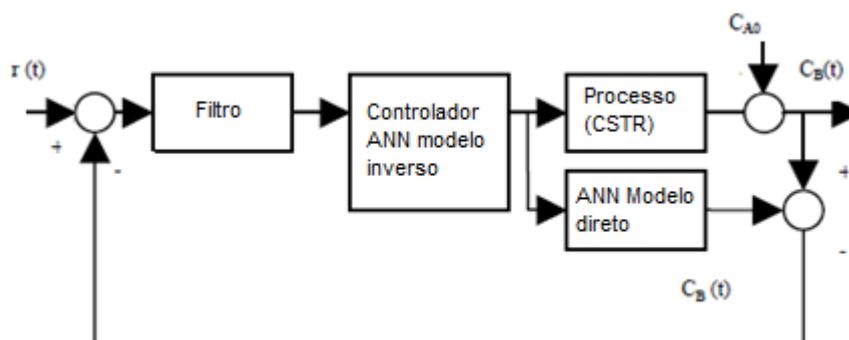
Figura 17 – Dados de teste da rede atuando como simulador.

Montanheiro (2004) estudou a aplicação de um controle preditivo não linear com a utilização de *ensembles* (ou conjuntos) de redes neurais. O autor comparou a utilização dos *ensembles* com as redes isoladas para o caso SISO do reator CSTR com reação de Van de Vusse. Conforme apresentado por Montanheiro (2004), a utilização dos controladores baseados em *ensembles* de redes neurais é promissor. Em seus estudos, os controladores baseados em redes isoladas normalmente apresentaram menor esforço de manipulação que os *ensembles*. Por outro lado, na maioria das vezes deixaram um erro residual no valor da variável controlada. Ainda segundo o autor, o esforço computacional e intelectual adicional para trabalho com os *ensembles* pode ser considerado desprezível, e seu uso pode levar a uma maior robustez do controlador.

Cunha Neto (2005) estudou a utilização de redes neurais para calcular os parâmetros de sintonia de controladores PID multimalhas em tempo real a partir de dados medidos pelo processo, tendo como modelo do processo o reator de Van de Vusse. A melhor rede obtida segundo o autor, foi uma rede RBF, a qual apresentou erros residuais pequenos, porém esses erros foram classificados como graves, pois o tipo de ação do controlador (reversa ou direta) foi previsto erroneamente em alguns casos. Cunha Neto (2005) ainda propôs um sistema de detecção e

diagnóstico de falhas utilizando redes neurais classificadoras para o mesmo processo, no qual as redes de mapas auto-organizáveis e RBFs se sobressaíram.

Anuradha *et al.* (2009) aplicaram um controle com redes neurais MLPs de modelo inverso, que em comparação com o controle PID se mostrou mais rápido para alterações no *setpoint* da variável controlada (C_B). Porém, ao realizar teste de perturbações na concentração de entrada do componente A (C_{Ain}), o controlador neuronal de modelo inverso apresentou um offset em relação ao *setpoint* desejado. Para melhorar o desempenho, os autores analisaram a adição de um modelo interno direto ao controlador de modelo inverso, conforme estrutura apresentada na Figura 18. Os mesmos testes foram aplicados a esse novo controlador, apresentando resultados satisfatórios. Neste trabalho, Anuradha *et al.* (2009) também utilizaram a aproximação para o caso de reator isotérmico (SISO).



Fonte: ANURADHA *et al.* (2009) - Adaptado

Figura 18 – Estrutura do controlador utilizado por ANURADHA *et al.* (2009).

Rodil & Fuente (2010) projetaram um controlador preditivo baseado em máquinas de vetores de suportes (SVN, do Inglês *Support Vector Machines*) buscando analisar a tolerância a falhas utilizando o modelo de Van de Vusse como referência. Os autores observaram que o MPC baseado em SVN, em conjunto com restrições adequadas e um modelo de predição de erro, exibe uma ação integral que permite alguma tolerância a falhas inferiores a um valor crítico, sem considerar alguma estratégia de tolerância a falhas em particular. Rodil & Fuente (2010) apresentaram uma estratégia de tolerância a falhas baseada num treinamento *on-line* do modelo da planta em falha (Algoritmo AOSVR). Os resultados mostraram eficácia do modelo em tolerância a falhas no reator de Van de Vusse, embora a observação de restrições possa comprometer desempenho do controlador.

4 APLICAÇÃO DO CONTROLE PID MULTIMALHAS

O modelo de Van de Vusse, descrito no Capítulo 3, foi submetido a um controle PID multimalhas para ser utilizado como referência para comparação dos resultados com os demais controladores estudados. O sistema de controle modelado no ambiente Simulink® é apresentado na Figura 19.

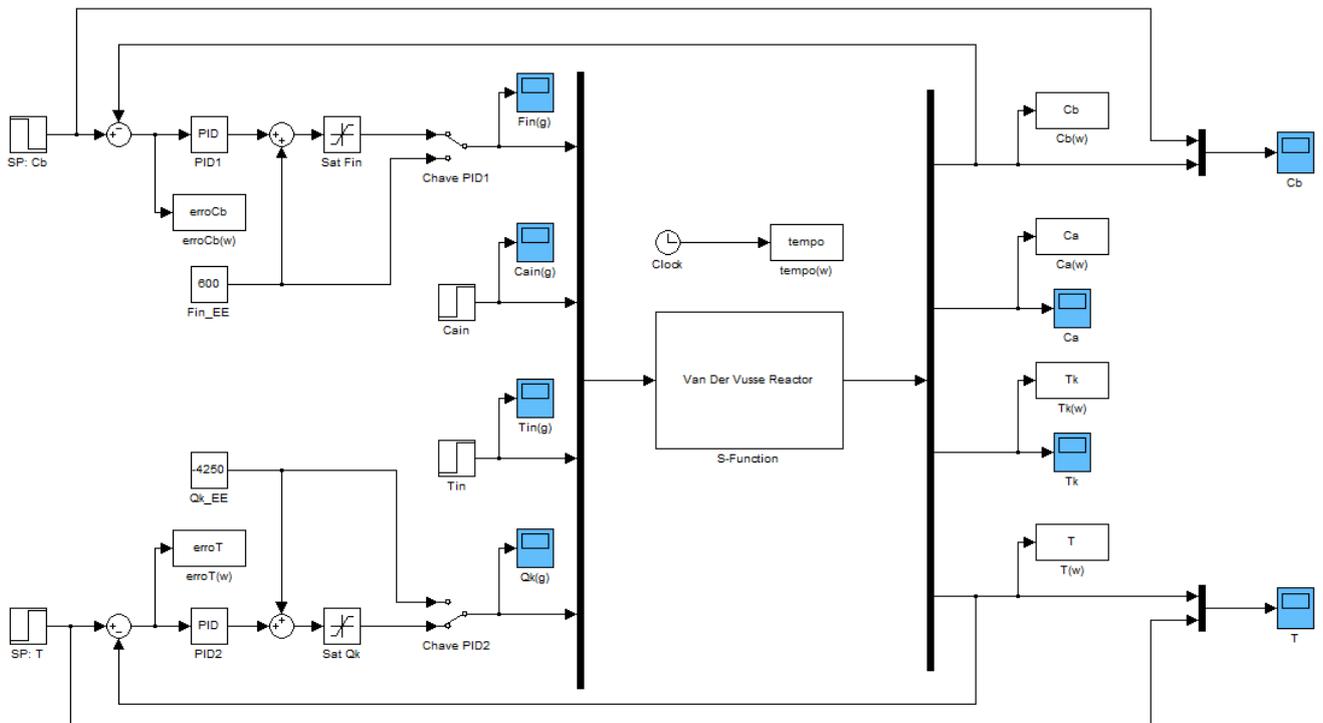


Figura 19 – Modelo com controle PID no Simulink®.

O objetivo foi sintonizar os controladores PIDs para investigar seu comportamento em mudanças de *setpoint* e distúrbios no processo. A Tabela 5 apresenta a relação de variáveis controladas e manipuladas para cada controlador, que foram definidas após análise da matriz de ganhos relativos e das funções de transferências apresentadas no Capítulo 3. O mesmo pareamento foi utilizado por outros autores (MONTANHEIRO, 2004; CUNHA NETO, 2005).

Tabela 5 – Relação de variáveis controladas e manipuladas para cada controlador.

Controlador	Variável Controlada	Variável Manipulada
PID1	C_B	F_{in}
PID2	T	Q_k

4.1 Sintonia da Malha de Concentração de B

A Figura 20 apresenta a análise do lugar das raízes da função de transferência $G_1(s) = C_B(s)/F_{in}(s)$ obtida no Capítulo 3.

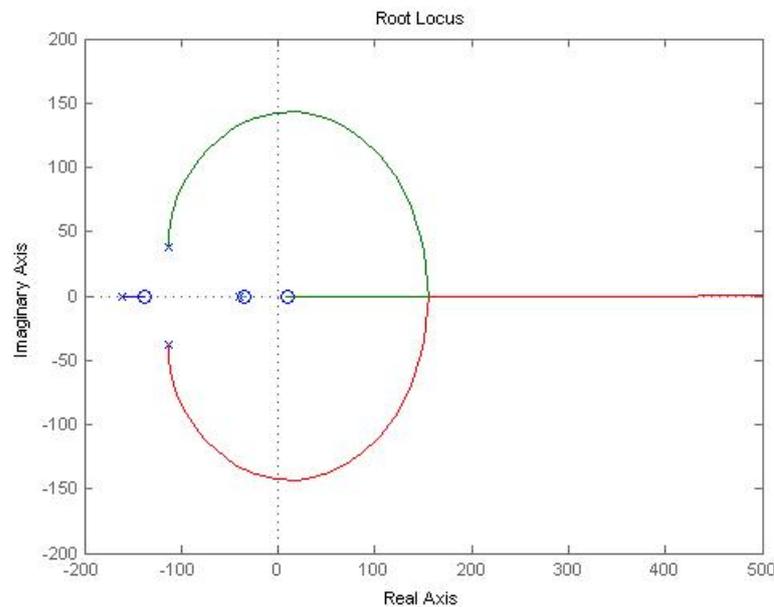


Figura 20 – Análise do lugar das raízes da função de transferência $G_1(s)$.

Pela análise da Figura 20, constata-se que o sistema em malha fechada pode instabilizar, sendo instável para ganhos do controlador acima do ganho crítico (k_{cr}), cujo valor é $2235,1 \text{ l}^2/(\text{mol}\cdot\text{h})$. Já a frequência crítica (ω_{cr}) é 143 rad/h , logo o período crítico (P_{cr}) é dado por $P_{cr} = 2\pi/\omega_{cr} = 0,044 \text{ h}$.

Pelo método de Ziegler & Nichols em malha fechada (OGUNNAIKE e RAY, 1994):

$$k_c = 0,45k_{cr} \quad ; \quad \tau_i = \frac{P_{cr}}{1,2} \quad (47)$$

A resposta em malha aberta para um degrau de -20% na vazão de alimentação no instante $t=0,02$ h é apresentada na Figura 21.

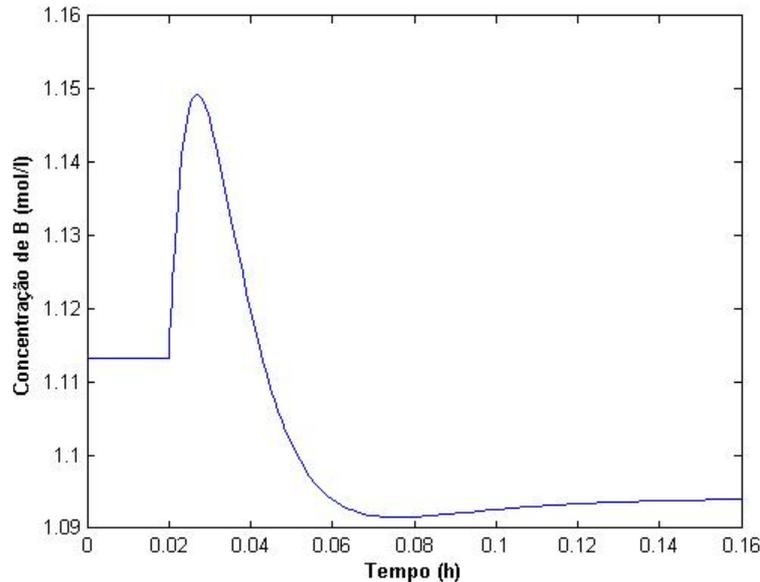


Figura 21 – Resposta em malha aberta para degrau de -20% em Fin no instante $t=0,02$ h.

Como pode ser observado pela Figura 21, o sistema tem característica de resposta inversa, ou seja, inicialmente o sistema vai numa direção oposta àquela na qual ele termina se estabelecendo.

$$G(s) = \frac{k_p(-\beta s + 1)}{\tau_p^2 s^2 + 2\zeta\tau_p s + 1}, \quad \beta > 0 \quad (48)$$

Utilizando o *toolbox* “ident” do Matlab® (R2010a), é possível estimar os valores do parâmetro para o sistema: $k_p = 1,65 \times 10^{-4}$ (mol.h)/l²; $\tau_p = 0,0081$ h; $\zeta = 0,815$; $\beta = 0,038$ h.

Pelo método de modelo de controle interno (IMC, do inglês Internal Model Control) para modelos de 2ª ordem com resposta inversa (SEBORG, 2004):

$$k_c k_p = \frac{2\zeta\tau_p}{\tau_c + \beta}; \quad \tau_i = 2\zeta\tau_p; \quad \tau_D = \frac{\tau_p}{2\zeta} \quad (49)$$

Em que τ_c é definida como a constante de tempo desejada para malha fechada, em geral $\tau_p > \tau_c > \theta$ (SEBORG *et al.*, 2004). Portanto, nesse caso, τ_c foi

escolhido como $\tau_p/3$. A Tabela 6 apresenta os resultados dos parâmetros do controlador para cada método.

Tabela 6 – Parâmetros do controlador PID para malha de concentração de B.

Parâmetro	IMC	Ziegler & Nichols (Malha fechada)
k_c	1966,0 l ² /mol.h	1005,8 l ² /mol.h
τ_i	0,0132 h	0,037 h
τ_D	4,96x10 ⁻³ h	-

A Figura 22 apresenta o resultado para uma simulação de alteração do *setpoint* da concentração de B (-0,1 mol/l), considerando somente a malha de controle de concentração de B operando com parâmetros do controlador obtidos pelo método IMC e de Ziegler & Nichols. Conforme pode ser observado, a sintonia pelo método IMC não convergiu para o *setpoint* desejado, devido à saturação da variável manipulada, em função da sintonia mais agressiva, enquanto a sintonia pelo método de Ziegler & Nichols em malha fechada conseguiu atingir o *setpoint* desejado. Portanto, para a malha de concentração, serão utilizados os parâmetros obtidos pelo método de Ziegler & Nichols em malha fechada.

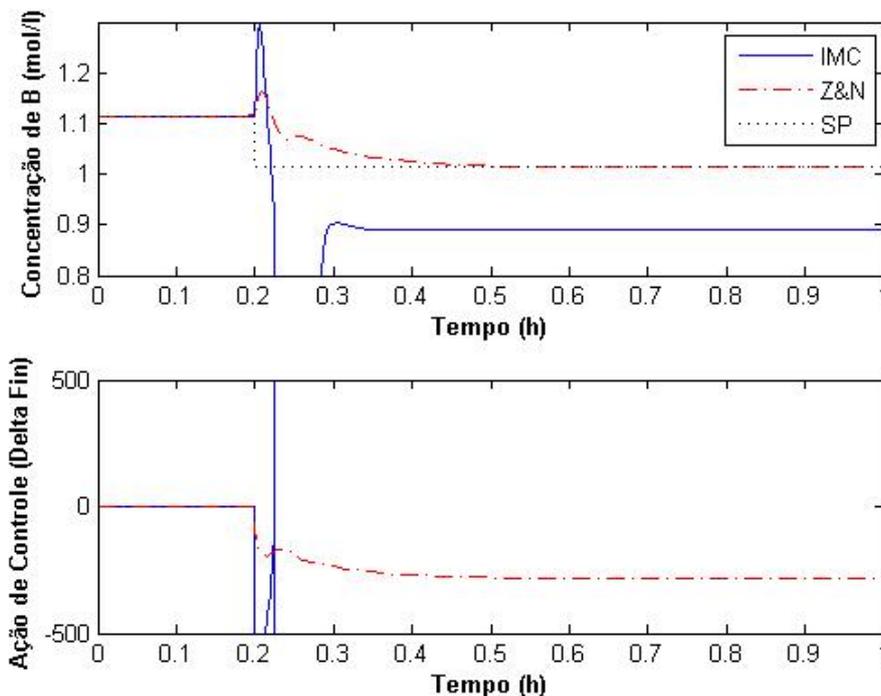


Figura 22 – Mudança de *setpoint* (-0,1 mol/l) – Sintonia malha de concentração de B.

4.2 Sintonia da Malha de Temperatura do Reator

A Figura 23 apresenta a análise do lugar das raízes da função de transferência $G_4(s) = T(s)/Q_k(s)$ obtida no Capítulo 3.

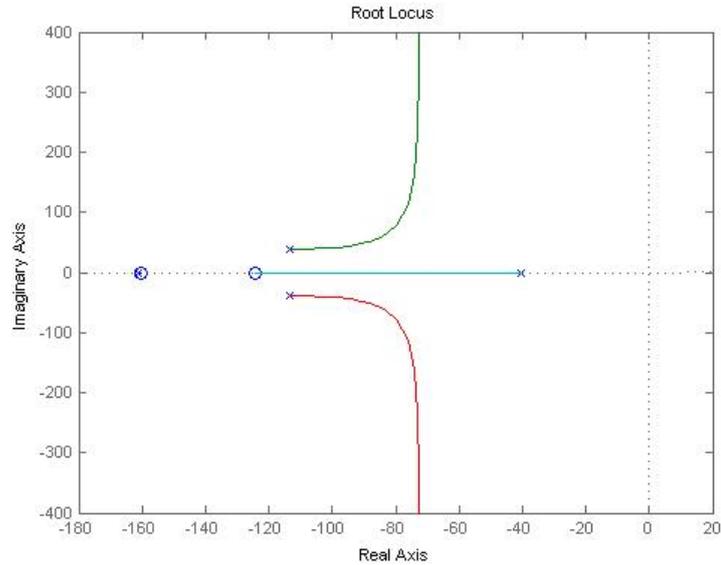


Figura 23 – Análise do lugar das raízes da função de transferência $G_4(s)$.

Como as raízes se encontram no semi-plano esquerdo para qualquer ganho do controlador, o sistema é estável. Logo, não existe ganho crítico e não é possível fazer a sintonia pelo método de Ziegler & Nichols de malha fechada.

A resposta em malha aberta para um degrau de 10% no calor retirado no instante $t=0,02$ h é apresentada na Figura 24.

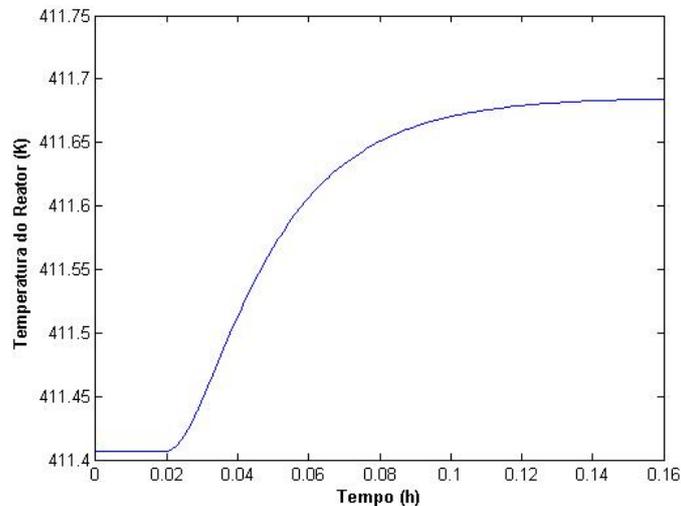


Figura 24 – Resposta em malha aberta para degrau de 10% em Q_k no instante $t=0,02$ h.

A resposta mostrada na Figura 24 é característica de modelos de 1ª ordem, com $\tau_p = 0,03$ h e $k_p = 6,7 \times 10^{-4}$ K/J/h.

$$G(s) = \frac{k_p}{\tau_p s + 1} \quad (50)$$

Pelo método IMC para modelos de 1ª ordem (SEBORG, 2004):

$$k_c k_p = \frac{\tau_p}{\tau_c} \quad ; \quad \tau_i = \tau_p \quad (51)$$

Pelo método de Ziegler & Nichols em malha aberta para modelos de 1º ordem (OGUNNAIKE & RAY, 1994):

$$k_c k_p = \frac{0,9 \tau_p}{\theta} \quad ; \quad \tau_i = 3,33 \theta \quad (52)$$

Em que θ é o tempo morto do sistema. A Tabela 7 apresenta os resultados dos parâmetros do controlador para cada método.

Tabela 7 – Parâmetros do controlador PID para malha de temperatura.

Parâmetro	IMC	Ziegler & Nichols (Malha aberta)
k_c	2105,3 J/h/K	14063 J/h/K
τ_i	0,03 h	0,017 h
τ_D	-	-

A Figura 25 apresenta o resultado para uma simulação de alteração do *setpoint* da temperatura do reator (+1K), considerando somente a malha de controle de temperatura operando com parâmetros dos controladores obtidos pelo método IMC e de Ziegler & Nichols. Conforme pode ser observado, a sintonia pelo método IMC apresentou ações de controles mais suaves com tempo de resposta semelhante. Portanto, para malha de temperatura, serão utilizados os parâmetros obtidos pelo método IMC.

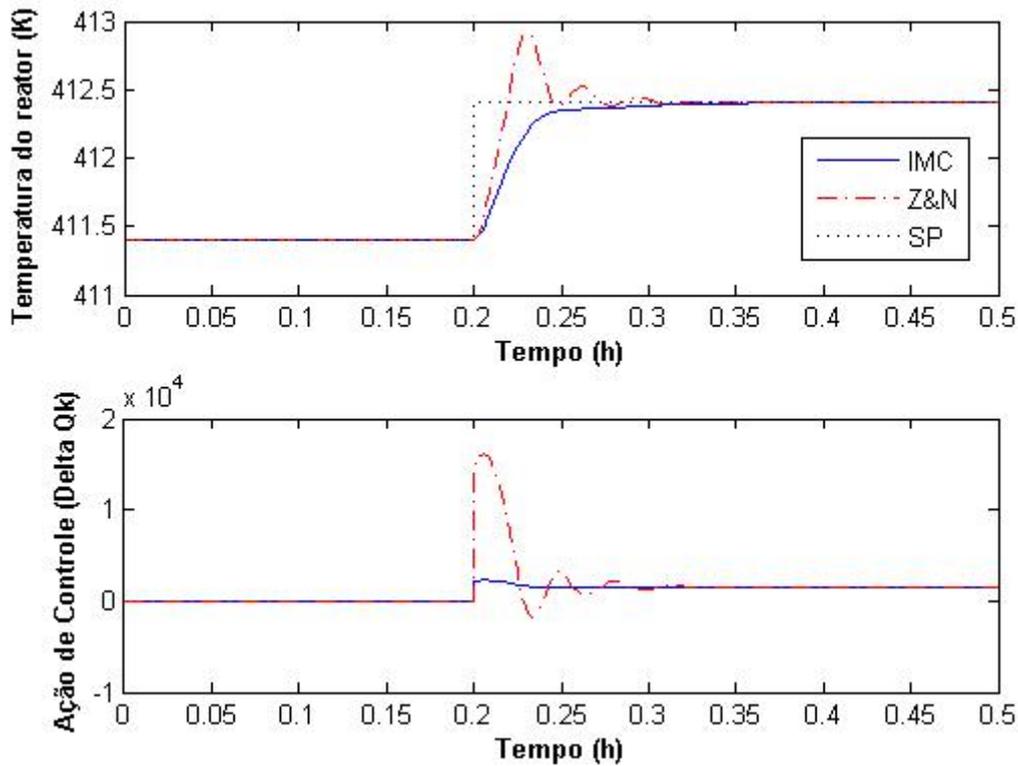


Figura 25 – Mudança de setpoint (+1K) – Sintonia malha de temperatura.

4.3 Método de *Detuning*

Para a utilização do controle PID multimalhas, foi utilizada uma técnica de *detuning*, onde inicialmente cada malha de controle é sintonizada separadamente, ignorando as interações com as outras malhas (Itens 4.1 e 4.2). Em seguida, as interações são levadas em conta reajustando (*detuning*) os parâmetros dos controladores.

Neste trabalho foi utilizado o método de *detuning* apresentado por Ogunnaike & Ray (1994).

$$k_c = \begin{cases} \left(\lambda + \sqrt{\lambda^2 - \lambda} \right) k_c^* & \lambda > 1 \\ \left(\lambda - \sqrt{\lambda^2 - \lambda} \right) k_c^* & \lambda < 1 \end{cases} \quad (53)$$

Em que:

k_c^* - Ganho proporcional do controlador sintonizado separadamente;

λ - Parâmetro de ganho relativo.

O parâmetro de ganho relativo é obtido através da matriz de ganhos relativos (RGA), e para a operação com razão de alimentação em torno de 60 h^{-1} seu valor é aproximadamente 1,0025. A Tabela 8 apresenta os parâmetros dos controladores obtidos após o método de *detuning*.

Tabela 8 – Parâmetros do controlador PID para malha de temperatura.

Parâmetro	PID1 (Malha Cb)	PID2 (Malha T)
k_c	957,9 l ² /mol.h	13394 J/h/K
τ_i	0,037 h	0,017 h
τ_D	-	-

4.4 Resultados

Com os parâmetros de sintonia obtidos, foram feitas simulações de alterações de *setpoints* e perturbações com as duas malhas (concentração de B e temperatura do reator) operando para analisar a funcionalidade do controle multimalhas no processo.

Para as variáveis manipuladas foram utilizadas as faixas de operação apresentadas na Tabela 9.

Tabela 9 – Limites utilizados para as variáveis manipuladas.

Variável	Limite inferior	Limite superior	Unidade
F_{in}	100	1600	mol/l
Q_k	-8500	0	kJ/h

As Figuras 26 e 27 apresentam os resultados da simulação de redução de *setpoint* da concentração de B (-0,1 mol/l). Neste caso, a malha de concentração de B consegue levar o processo à nova condição de *setpoint*, enquanto a malha de temperatura mantém o *setpoint* de temperatura.

As Figuras 28 e 29 apresentam os resultados da simulação de uma perturbação na concentração de A na alimentação (+10%). Assim como na primeira simulação, o controle é efetivo.

Em ambas as simulações, a alteração (redução de *setpoint* ou perturbação) não levou o processo para uma região de inversão de ganho, o que explica o sucesso do controle PID multimalhas nestas situações.

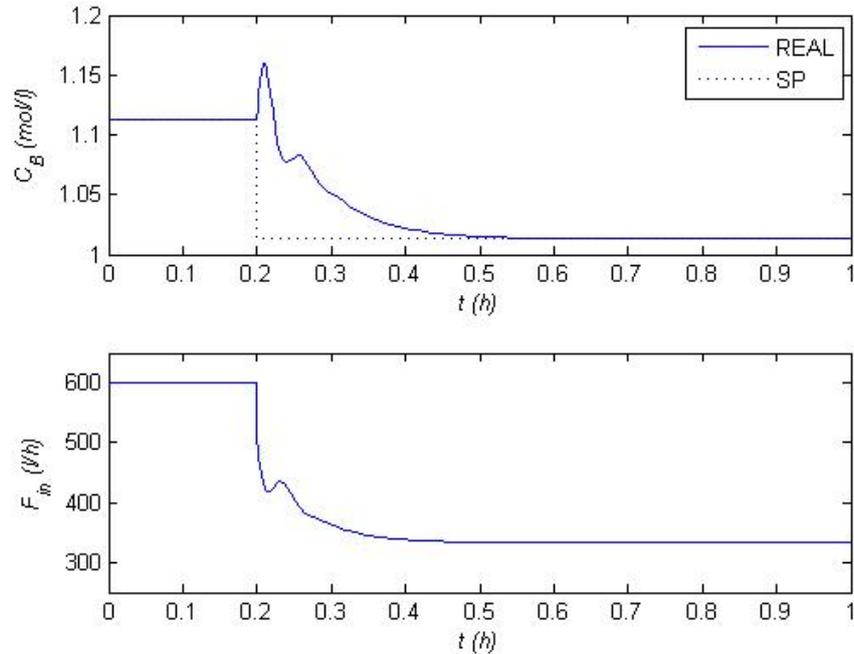


Figura 26 – Mudança de *setpoint* (-0,1 mol/l) – Malha de C_B .

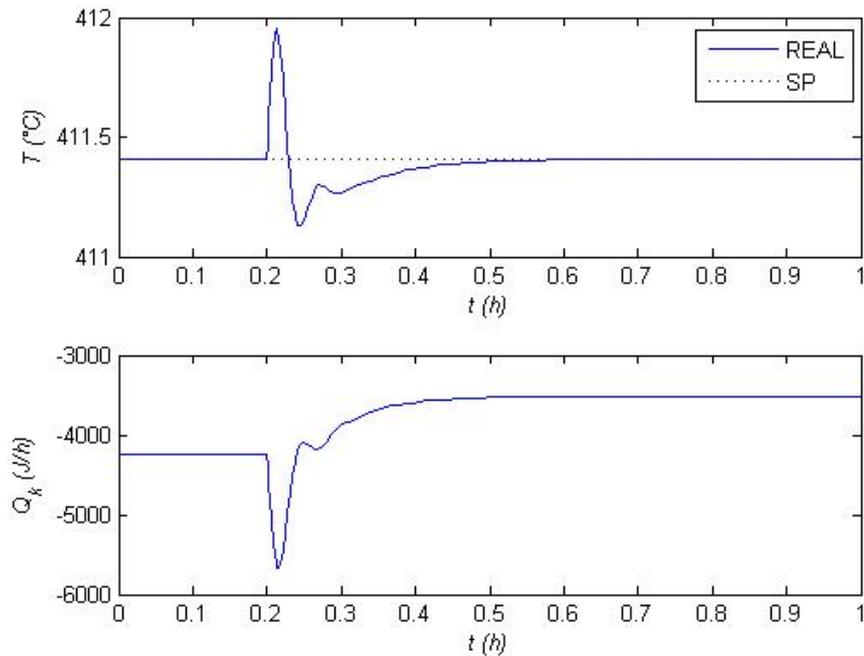


Figura 27 – Mudança de *setpoint* (-0,1 mol/l) – Malha de T .

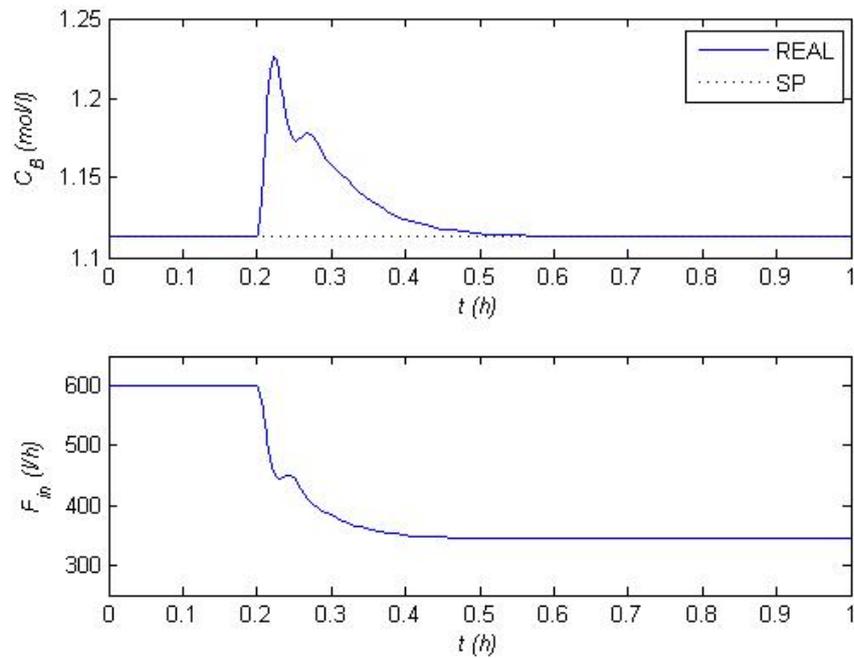


Figura 28 – Perturbação na concentração de A na alimentação (+10%) – Malha de C_B .

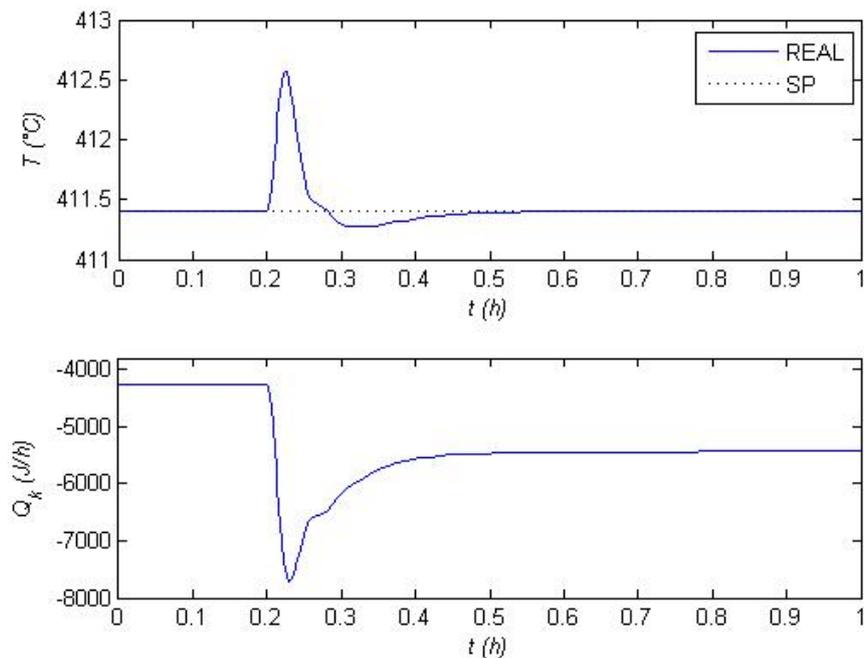


Figura 29 – Perturbação na concentração de A na alimentação (+10%) – Malha de T .

As Figuras 30 e 31 apresentam os resultados da simulação do aumento de *setpoint* na concentração de B (+0,1 mol/l). Como pode ser observado, este *setpoint* é inalcançável para os dados de processo considerados, portanto, o controle nesse caso deveria manter a operação no ponto máximo possível para a condição. Porém, vemos que a vazão foi levada até o valor máximo (1600 l/h) e conseqüentemente a concentração de B foi afastada de seu valor máximo, ou seja, o controlador

instabilizaria o processo, caso não se tivesse imposto saturações nas ações de controle.

Este resultado já era esperado, uma vez que o novo *setpoint* leva o processo para a região de inversão de ganho, e como os ganhos dos controladores sintonizados são positivos, o controle proporcional integral tende a aumentar a vazão para minimizar o erro, o que na prática só aumenta o erro.

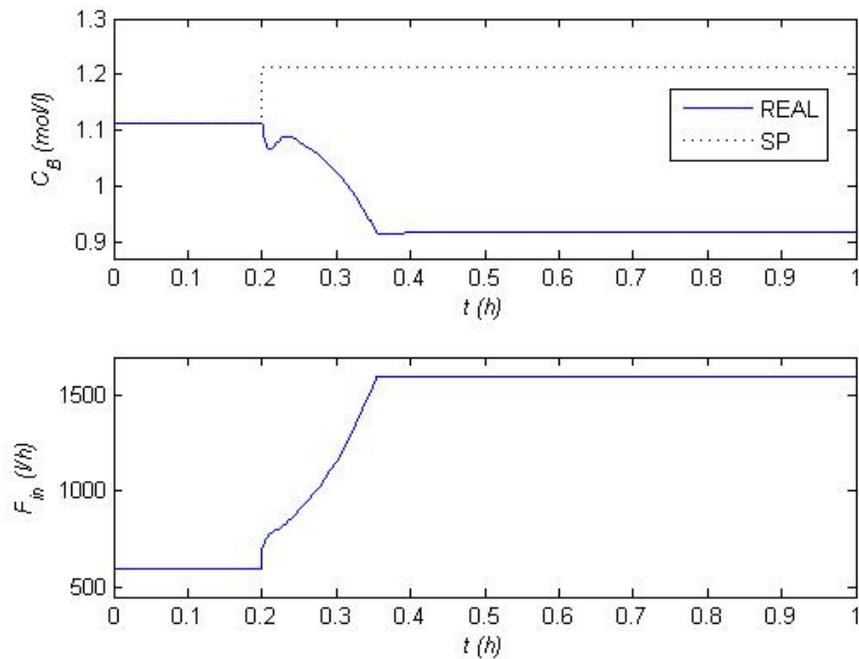


Figura 30 – Mudança de *setpoint* (+0,1 mol/l) – Malha de C_B .

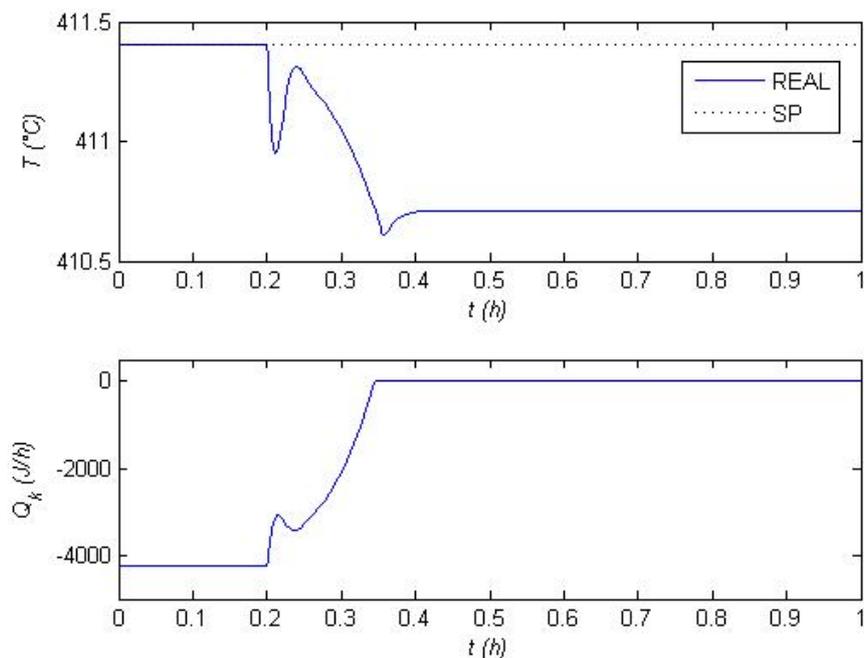


Figura 31 – Mudança de *setpoint* (+0,1 mol/l) – Malha de T .

5 IDENTIFICAÇÃO COM REDES NEURONAIS

5.1 Geração de Dados para Treinamento

Os padrões a serem utilizados para treinamento foram obtidos através de simulações em malha aberta, variando aleatoriamente os dados de entrada (Vazão de alimentação e Calor retirado pela camisa) e as perturbações (Concentração de A e Temperatura na alimentação). A Tabela 10 apresenta os limites utilizados para cada variável.

Tabela 10 – Limites das variáveis utilizados para geração de padrões.

Variável	Limite Inferior	Limite Superior	Unidade
F_{in}	10	1600	l/h
Q_k	-8500	0	kJ/kg
C_{Ain}	4	6	mol/l
T_{in}	385	415	K

O tempo de simulação utilizado para todos os grupos de dados foi de 0,1h, tempo mínimo estimado para alcance do estado estacionário. A escolha do tempo de amostragem deve atender o compromisso entre beneficiar a identificação e o projeto do controlador (NORGAARD *et al.*, 2000). Segundo Meleiro (2002), uma alta frequência de amostragem permite maior rapidez de resposta, possibilitando ações de controle mais suaves, porém problemas de mau condicionamento numérico tendem a ser mais pronunciados. Por outro lado, períodos de amostragem muito longos podem implicar na perda de dinâmicas mais rápidas. Cooper (2007) aponta, como boa prática, que o tempo de amostragem deve ser inferior a 10% da constante de tempo do sistema, para que se consiga caracterizar a dinâmica do sistema. Desta forma, para investigar a sua influência na identificação e controle do processo, foram recolhidos dados utilizando diferentes tempos de amostragem: 0,002h, 0,004h e 0,008h.

Os demais parâmetros do processo foram mantidos os mesmos apresentados nas Tabelas 3 e 4.

A Figura 32 apresenta um mapa dos pares gerados de vazão de alimentação (F_{in}) e calor retirado pela camisa (Q_k) considerando o tempo de amostragem de 0,002h. Os dados foram distribuídos uniformemente em todo limite de aplicação das variáveis. As demais variáveis (C_{Ain} e T_{in}) também foram variadas de maneira uniforme. Os dados gerados com os outros tempos de amostragem (0,004h e 0,008h) seguem a mesma distribuição uniforme.

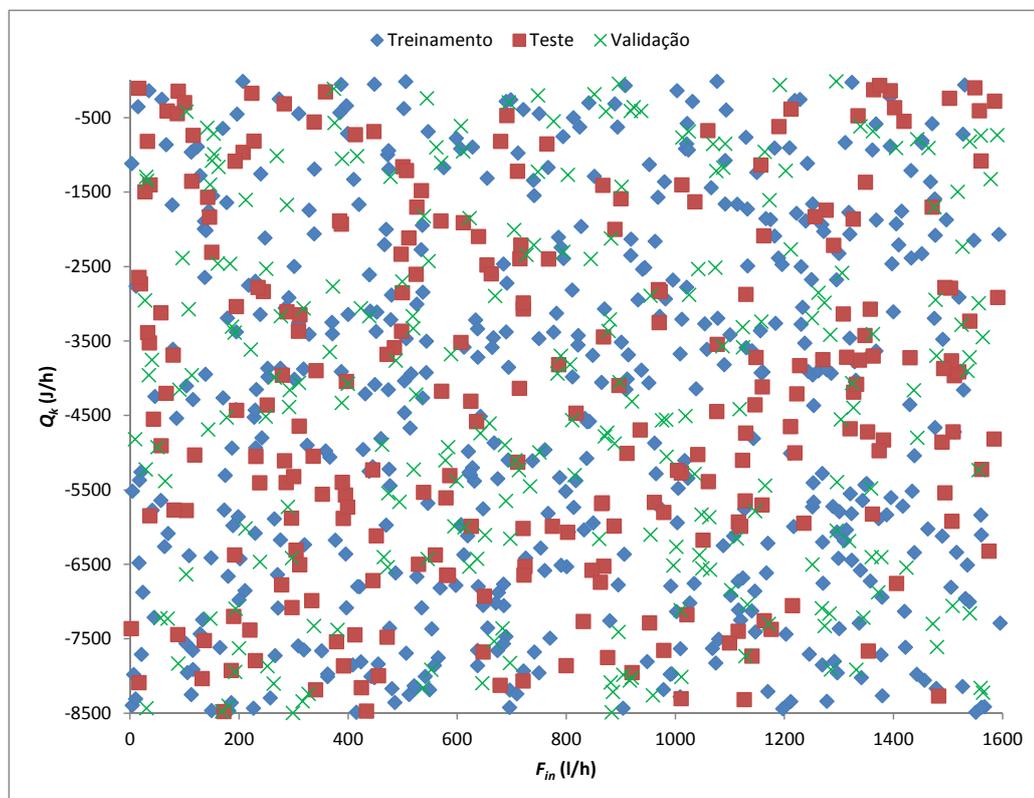


Figura 32 – Mapa de pontos simulados (tempo de amostragem de 0,002h).

5.2 Treinamento das Redes Neurais

Conforme visto anteriormente no item 2.4.1.4, para estratégia de controle baseada no modelo indireto, podem ser adotadas duas arquiteturas diferentes para as redes. A primeira fornece diretamente como saída as P previsões no futuro, já a segunda, produz uma previsão um passo adiante que é realimentada à rede como uma entrada para o cálculo da próxima previsão, os outros dados de entrada da

rede são deslocados para trás de uma unidade e isto é feito iterativamente até que n predições tenham sido obtidas.

De Souza Jr. (1993) apresentou algumas desvantagens da primeira estratégia, conforme apresentado no item 2.4.1.4, que justificam a escolha no presente trabalho pela modelagem baseada na segunda estratégia.

Como entrada da rede foram utilizados dados passados das variáveis de entrada (vazão de alimentação e calor retirado pela camisa), perturbações (concentração de A na alimentação e temperatura da alimentação) e variáveis controladas (concentração de B e temperatura do reator). A saída da rede é composta pela concentração de B e temperatura do reator preditas. Inicialmente foram treinadas redes únicas capazes de prever as duas variáveis controladas. Utilizando os padrões gerados, as redes foram treinadas no software STATISTICA®.

A Figura 33 apresenta a estrutura básica das redes neuronais utilizadas.

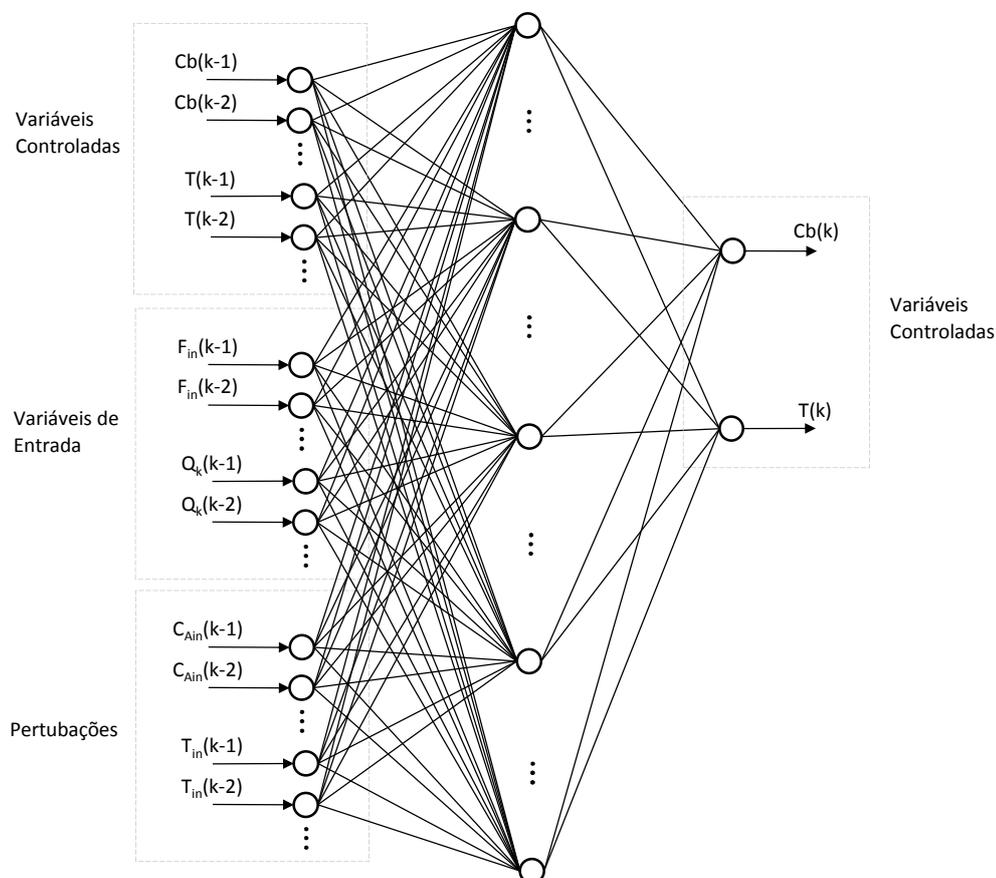


Figura 33 – Estrutura básica das redes neuronais.

Inicialmente as simulações foram feitas utilizando um, dois e três dados atrasados. Porém, ao se utilizar três dados atrasados não se obteve convergência, provavelmente devido à grande quantidade de variáveis, e conseqüentemente parâmetros das redes obtidas.

As Tabelas 11, 12 e 13 apresentam os resultados de configuração e desempenho das melhores redes obtidas para cada tempo de amostragem, 0,002h, 0,004h e 0,008h, respectivamente. Todas as redes encontradas possuem função de ativação linear na camada de entrada e de saída, e função de ativação hiperbólica na camada escondida.

A performance da rede é dada pela razão SD, definida como a razão entre o desvio padrão obtido pela diferença entre os valores preditos e os valores reais e o desvio padrão dos dados reais. Modelos com razão SD ligeiramente inferiores a 1,0 realizam predições de ruins a razoáveis, modelos com razão SD no intervalo entre 0,2 e 0,1 já têm usualmente desempenho muito bons. Em geral, pode-se afirmar que quanto menor o valor da razão SD melhor pode ser considerado o desempenho da rede (DE SOUZA JR., 2010).

Tabela 11 – Redes obtidas para tempo de amostragem igual a 0,002h.

Tipo	Dados atrasados	Quantidade de neurônios			Quantidade de Parâmetros	Razão SD (C_B)	Razão SD (T)
		Camada de entrada	Camada escondida	Camada de saída			
Linear	1	6	-	2	14	0,0686	0,0439
Linear	2	12	-	2	26	0,0199	0,0166
MLP	1	6	11	2	101	0,0517	0,0190
MLP	2	12	13	2	197	0,0145	0,0126

Tabela 12 – Redes obtidas para tempo de amostragem igual a 0,004h.

Tipo	Dados atrasados	Quantidade de neurônios			Quantidade de Parâmetros	Razão SD (C_B)	Razão SD (T)
		Camada de entrada	Camada escondida	Camada de saída			
Linear	1	6	-	2	14	0,1343	0,0827
Linear	2	12	-	2	26	0,0612	0,0429
MLP	1	6	11	2	101	0,0947	0,0263
MLP	2	12	13	2	197	0,0310	0,0307

Tabela 13 – Redes obtidas para tempo de amostragem igual a 0,008h.

Tipo	Dados atrasados	Quantidade de neurônios			Quantidade de Parâmetros	Razão SD (C _B)	Razão SD (T)
		Camada de entrada	Camada escondida	Camada de saída			
Linear	1	6	.	2	14	0,2457	0,1433
Linear	2	12	-	2	26	0,1419	0,0848
MLP	1	6	11	2	101	0,1507	0,0697
MLP	2	12	13	2	197	0,0541	0,0317

Nas Figuras 34 a 36 são apresentados os dados preditos versus os dados reais para a concentração de B e temperatura do reator (redes MLP e Lineares) considerando os tempos de amostragem de 0,002h, 0,004h e 0,008h, respectivamente. As denominações 1 ou 2 após o tipo de rede se referem a quantidades de dados atrasados da rede.

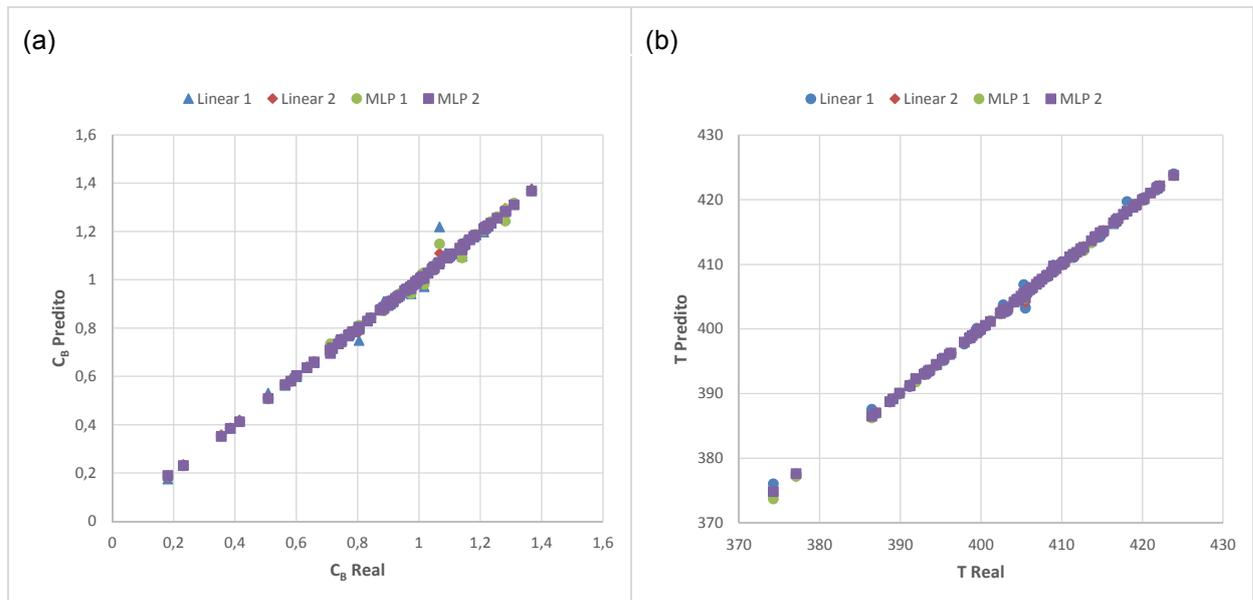


Figura 34 – Dados preditos versus dados reais para tempo de amostragem de 0,002h
(a) Concentração de B (b) Temperatura do reator.

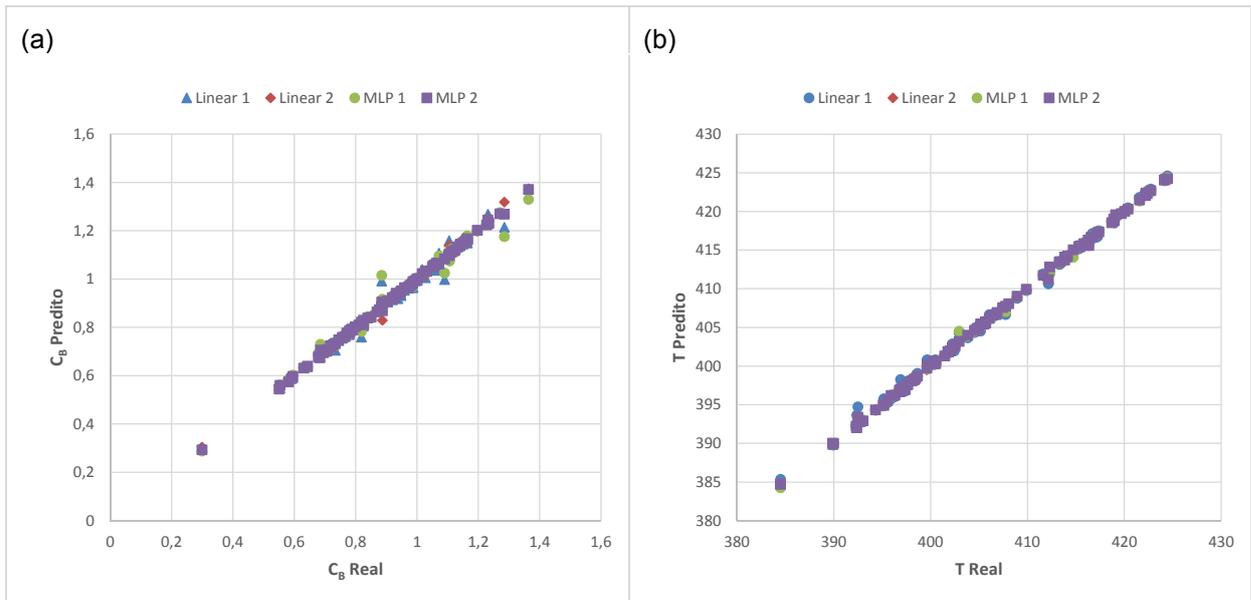


Figura 35 – Dados preditos versus dados reais para tempo de amostragem de 0,004h
(a) Concentração de B (b) Temperatura do reator.

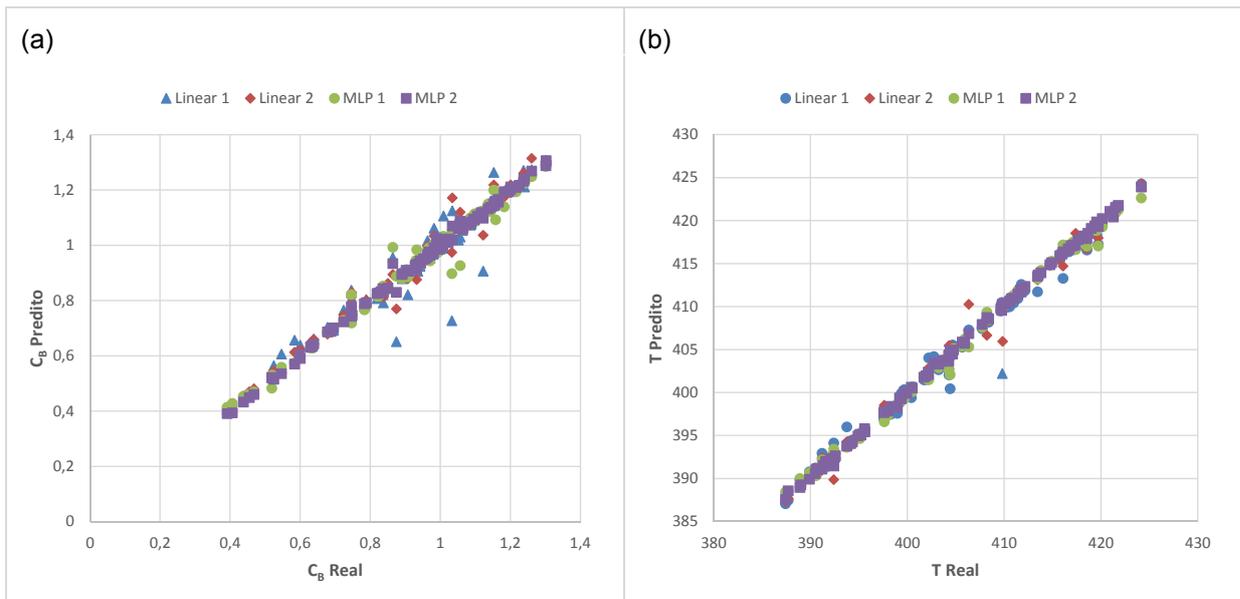


Figura 36 – Dados preditos versus dados reais para tempo de amostragem de 0,008h
(a) Concentração de B (b) Temperatura do reator.

Como pode ser observado pelos parâmetros de desempenho e pelas figuras, foi possível obter redes neurais com boa capacidade de predição de 1 passo adiante para todas as situações, inclusive as redes lineares obtiveram bons desempenho. Porém, para utilização no controle preditivo, as redes devem ser capazes de prever P passos adiante. No item subsequente é apresentada a avaliação da capacidade de predição da dinâmica do processo para P passos futuros de cada rede obtida.

5.3 Avaliação da Capacidade de Predição das Redes

Para avaliar o desempenho das redes obtidas, gerou-se um grupo de dados de teste, sendo variações impostas na vazão de alimentação da ordem de 200 l/h, com tempo de duração de 0,2 h. A Figura 37 mostra as perturbações aplicadas à vazão de alimentação.

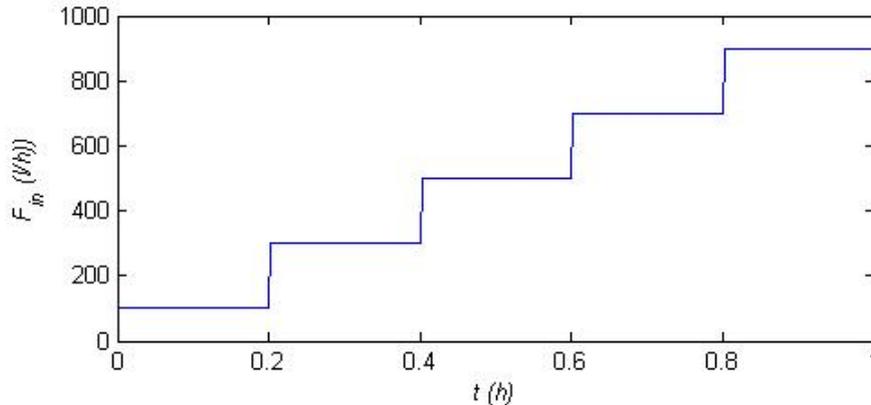


Figura 37 – Perturbações aplicadas a vazão de alimentação.

As redes foram utilizadas como simulador, ou seja, os valores das saídas foram realimentados para cálculo das novas previsões. Os resultados são apresentados nas Figuras 38 a 43.

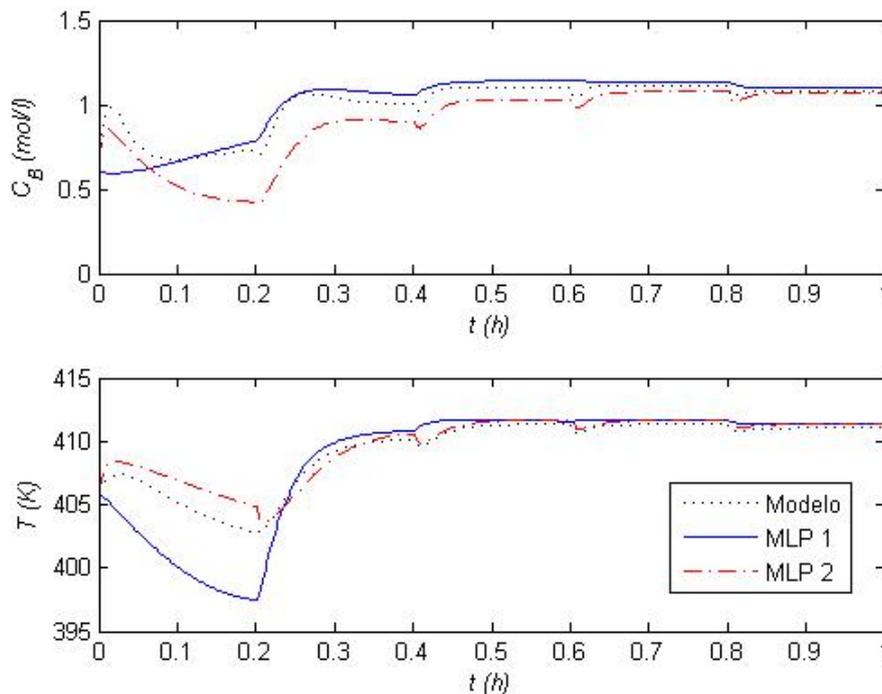


Figura 38 – Simulação redes MLP com tempo de amostragem de 0,002h.

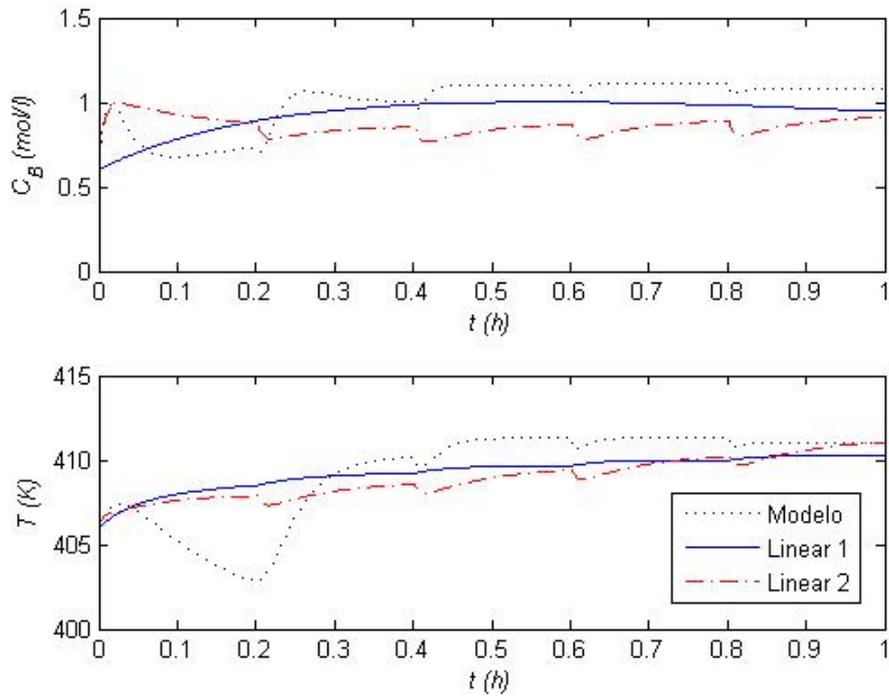


Figura 39 – Simulação redes lineares com tempo de amostragem de 0,002h.

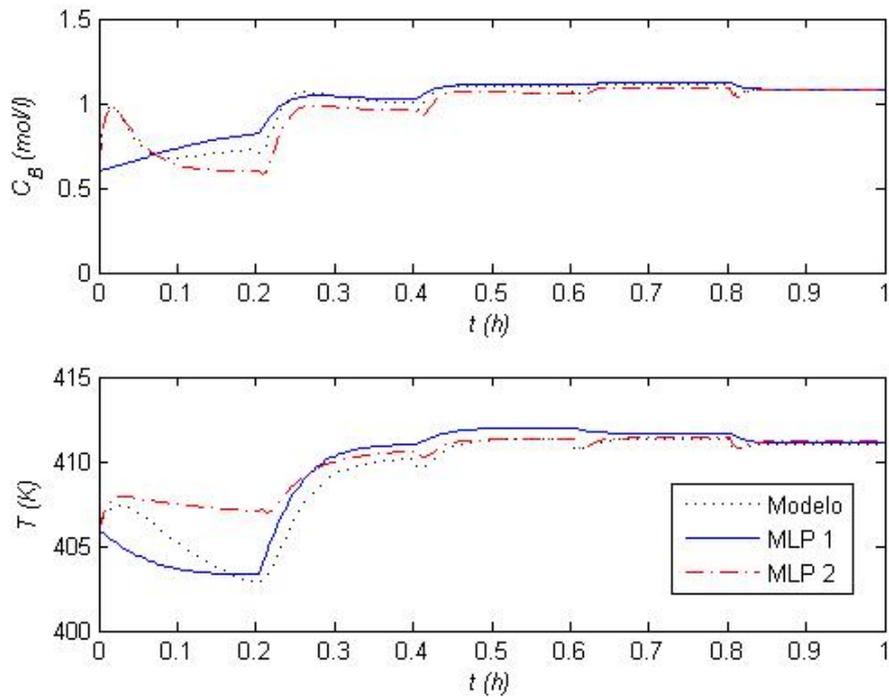


Figura 40 – Simulação redes MLP com tempo de amostragem de 0,004h.

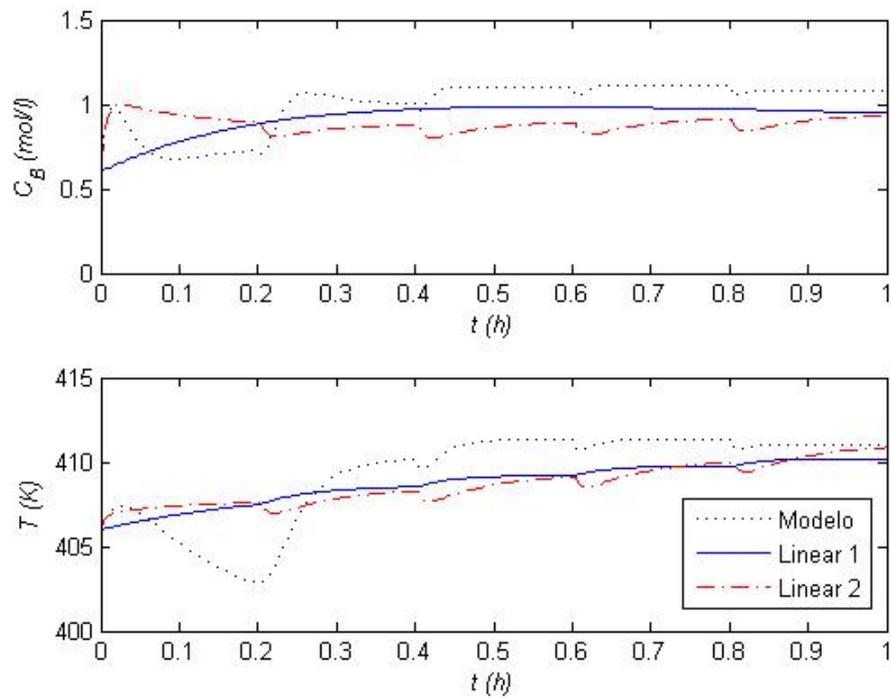


Figura 41 – Simulação redes lineares com tempo de amostragem de 0,004h.

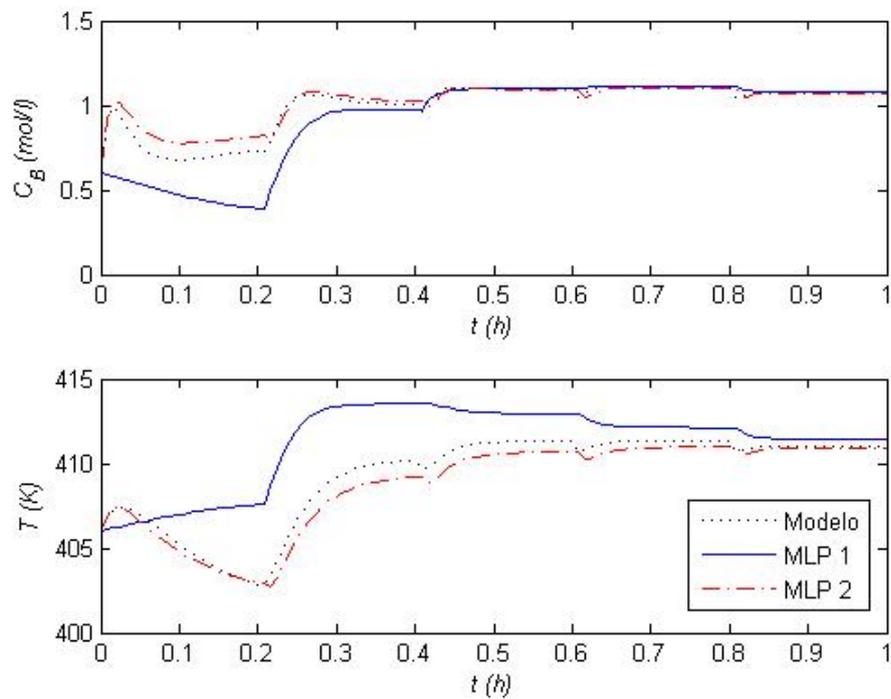


Figura 42 – Simulação redes MLP com tempo de amostragem de 0,008h.

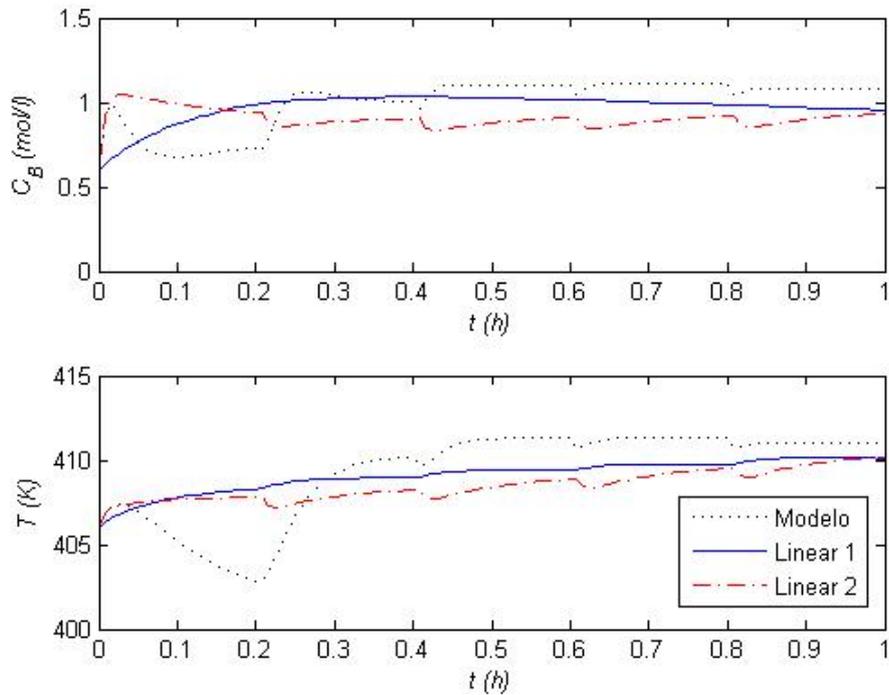


Figura 43 – Simulação redes lineares com tempo de amostragem de 0,008h.

De modo a avaliar melhor os resultados das Figuras 38 a 43, foram calculados os somatórios dos erros quadráticos ($\sum E^2$). Para compatibilizar os resultados dos diferentes tempos de amostragem, o mesmo foi dividido pela quantidade de dados disponíveis (N) em cada caso.

Tabela 14 – Comparação dos erros de cada tempo de amostragem, tipo de rede e quantidade de dados atrasados.

Tempo de amostragem (h)	Tipos	Quantidade de dados atrasados	$\sum E^2 / N(C_B)$	$\sum E^2 / N(T)$
0,002	Linear	1	0,014	4,20
		2	0,051	4,04
	MLP	1	0,006	4,38
		2	0,018	0,66
0,004	Linear	1	0,016	3,58
		2	0,042	4,40
	MLP	1	0,005	1,01
		2	0,003	1,99
0,008	Linear	1	0,016	4,28
		2	0,043	5,43
	MLP	1	0,021	6,51
		2	0,002	0,39

As redes lineares, assim como as redes MLPs com um dado atrasado, não conseguiram prever muito bem o comportamento dinâmico do sistema, apesar de os resultados do treinamento das redes para um passo de predição serem muito bons, em alguns casos até superiores aos resultados das redes MLPs com dois dados atrasados. Este resultado já era esperado devido à característica não linear do processo.

As redes MLPs com dois dados atrasados conseguiram prever relativamente bem o comportamento dinâmico do sistema, porém apresentaram alguns desvios em relação ao modelo principalmente no início das simulações. Com relação ao tempo de amostragem, as diferenças são relativamente pequenas, apresentando melhores resultados os tempo de 0,004 e 0,008h.

Para tentar eliminar os desvios obtidos, e melhorar a aderência das redes ao modelo, foram treinadas redes individuais para cada variável controlada. Como os resultados das redes lineares e MLPs com um dado atrasado para as simulações anteriores não foram satisfatórios, essas configurações foram descartadas e portanto, foram treinadas apenas redes MLPs individuais com dois dados atrasados.

As Tabelas 15, 16 e 17 apresentam as melhores redes individuais obtidas em cada tempo de amostragem. Assim como para as redes individuais, todas as redes obtidas apresentam função de ativação linear nas camadas de entrada e de saída, e função de ativação hiperbólica na camada escondida.

Tabela 15 – Redes individuais obtidas para tempo de amostragem igual a 0,002h.

Rede	Tipo	Dados atrasados	Quantidade de neurônios			Quantidade de Parâmetros	Razão SD (C_B)	Razão SD (T)
			Camada de entrada	Camada escondida	Camada de saída			
C_B	MLP	2	12	13	1	183	0,016	-
T	MLP	2	12	13	1	183	-	0,0132

Tabela 16 – Redes individuais obtidas para tempo de amostragem igual a 0,004h.

Rede	Tipo	Dados atrasados	Quantidade de neurônios			Quantidade de Parâmetros	Razão SD (C_B)	Razão SD (T)
			Camada de entrada	Camada escondida	Camada de saída			
C_B	MLP	2	12	13	1	183	0,035	-
T	MLP	2	12	13	1	183	-	0,0172

Tabela 17 – Redes individuais obtidas para tempo de amostragem igual a 0,008h.

Rede	Tipo	Dados atrasados	Quantidade de neurônios			Quantidade de Parâmetros	Razão SD (C_B)	Razão SD (T)
			Camada de entrada	Camada escondida	Camada de saída			
C_B	MLP	2	12	13	1	183	0,052	-
T	MLP	2	12	13	1	183	-	0,019

As mesmas simulações feitas anteriormente com as redes únicas foram repetidas com as redes MLP individuais com dois dados atrasados. As Figuras 44 a 46 apresentam os resultados obtidos para cada tempo de amostragem. Os erros calculados são mostrados na Tabela 18.

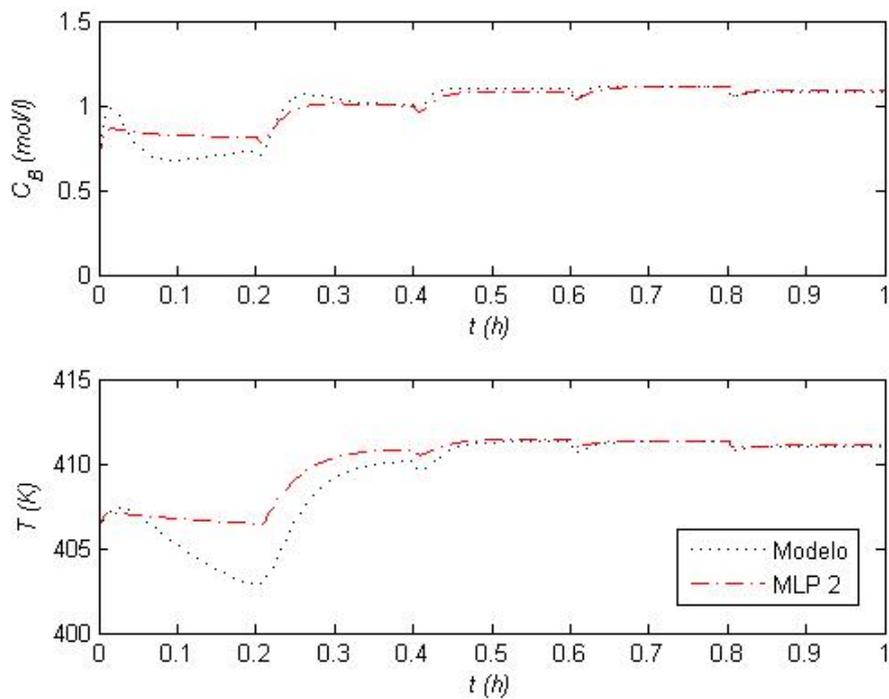


Figura 44 – Simulação redes MLP individuais com tempo de amostragem de 0,002h.

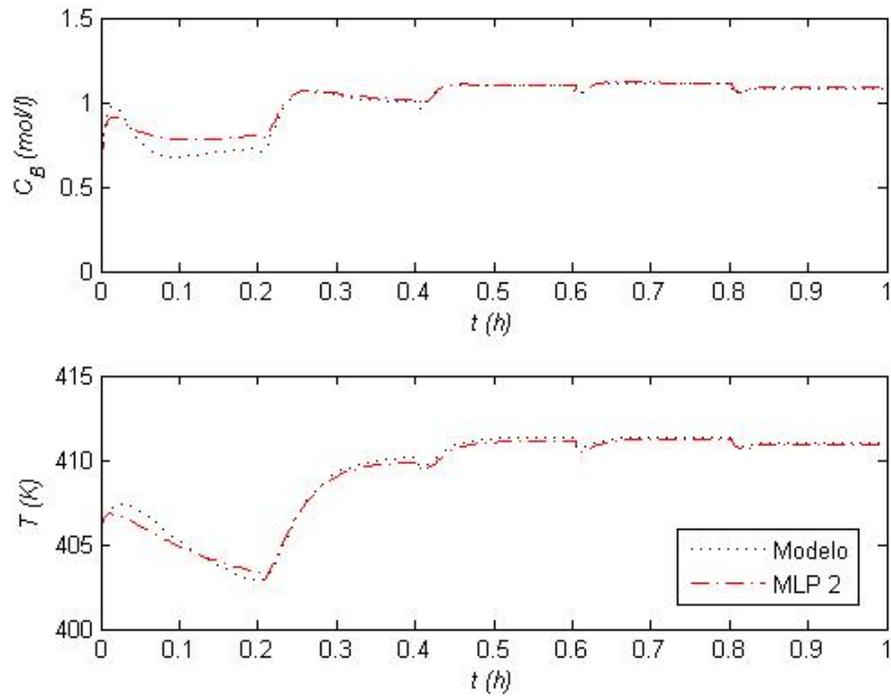


Figura 45 – Simulação redes MLP individuais com tempo de amostragem de 0,004h.

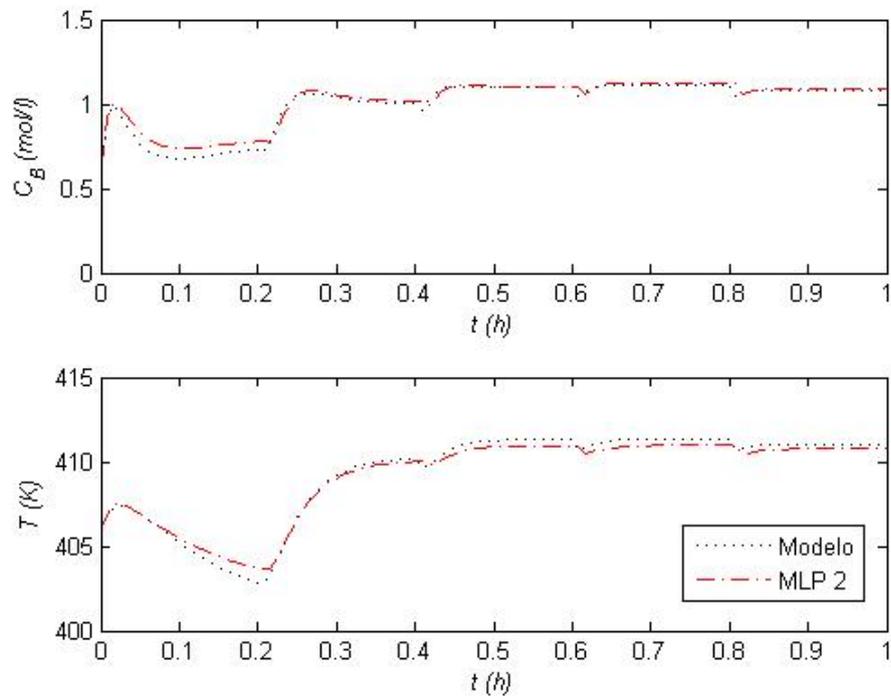


Figura 46 – Simulação redes MLP individuais com tempo de amostragem de 0,008h.

Tabela 18 – Comparação dos erros de cada tempo de amostragem para as redes individuais.

Tempo de amostragem (h)	Tipos	Quantidade de dados atrasados	$\sum E^2 / N(C_B)$	$\sum E^2 / N(T)$
0,002	MLP	2	0,003	1,61
0,004	MLP	2	0,001	0,08
0,008	MLP	2	0,001	0,07

Conforme pode ser observado, a utilização de redes individuais para cada variável controlada melhorou bastante o resultado anterior considerando redes únicas prevendo as duas variáveis controladas, praticamente eliminando os desvios. Pelos resultados, espera-se que as rede individuais apresentem melhores resultados de controle, porém, as redes únicas também serão consideradas para estudo dos controladores, visto que os pequenos desvios apresentados podem ser naturalmente corrigidos por termos corretivos a serem utilizados na função objetivo.

Os resultados do tempo de amostragem 0,002 h é ligeiramente inferior aos demais tempos. Praticamente não foi observada diferença entre os tempos de amostragem de 0,004 e 0,008 h, ambos apresentando ótima aderência ao modelo.

A mesma simulação do comportamento do processo no estado estacionário apresentada nas Figuras 12 e 13, foram realizadas considerando as melhores redes MLPs únicas e individuais obtidas. Os resultados, para cada tempo de amostragem, são apresentados nas Figuras 47, 48 e 49. Os desvios podem ser visualizados na Tabela 19.

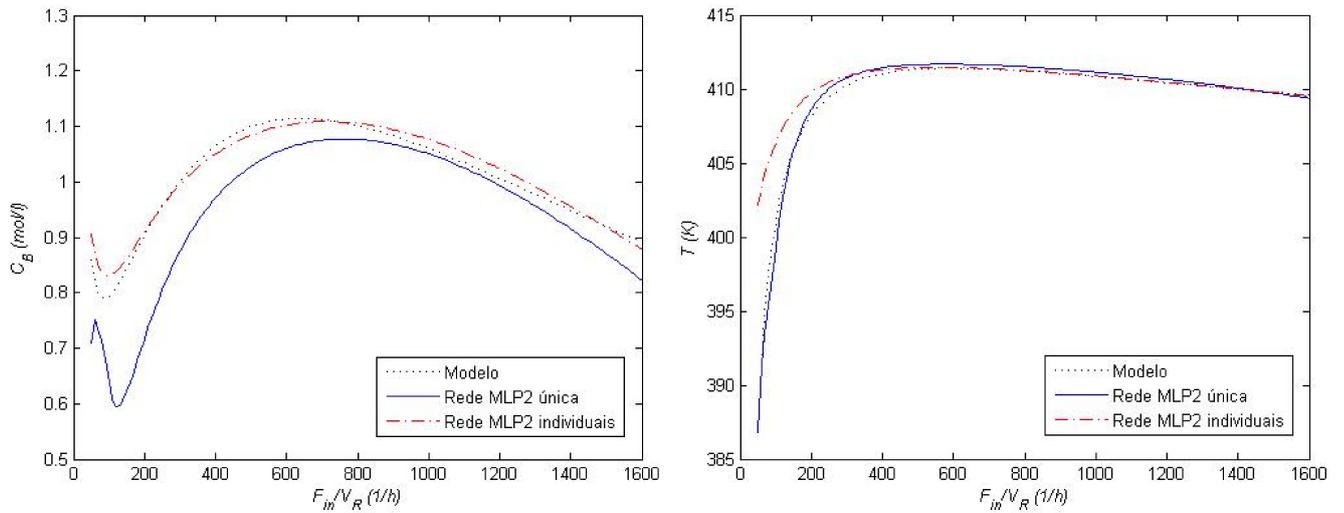


Figura 47 – Comportamento estacionário do processo considerando as redes com tempo de amostragem de 0,002h.

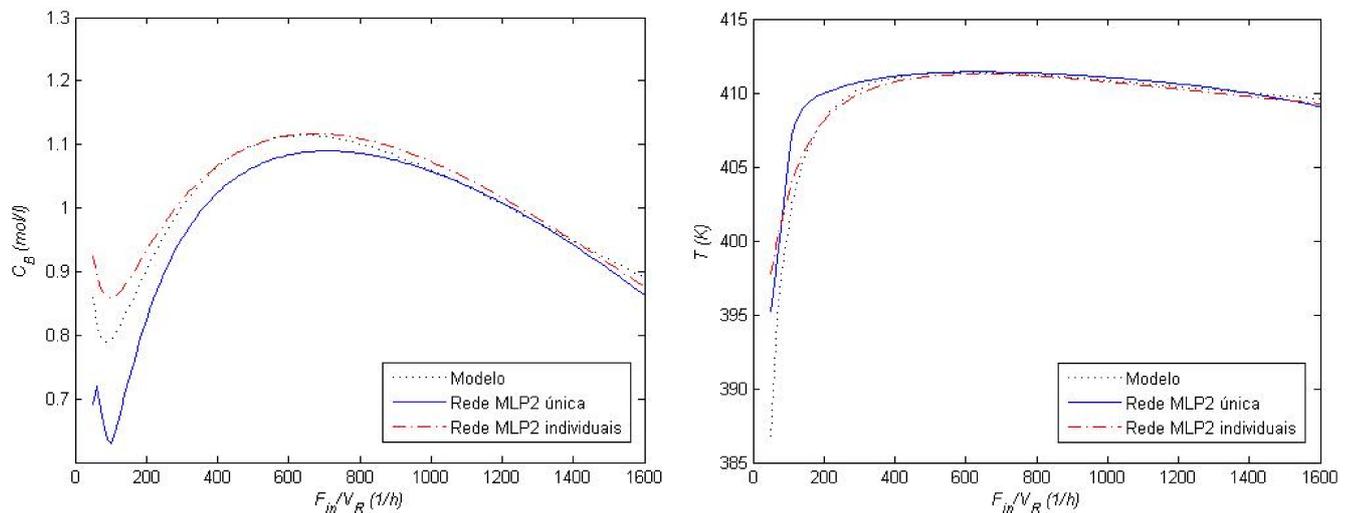


Figura 48 – Comportamento estacionário do processo considerando as redes com tempo de amostragem de 0,004h.

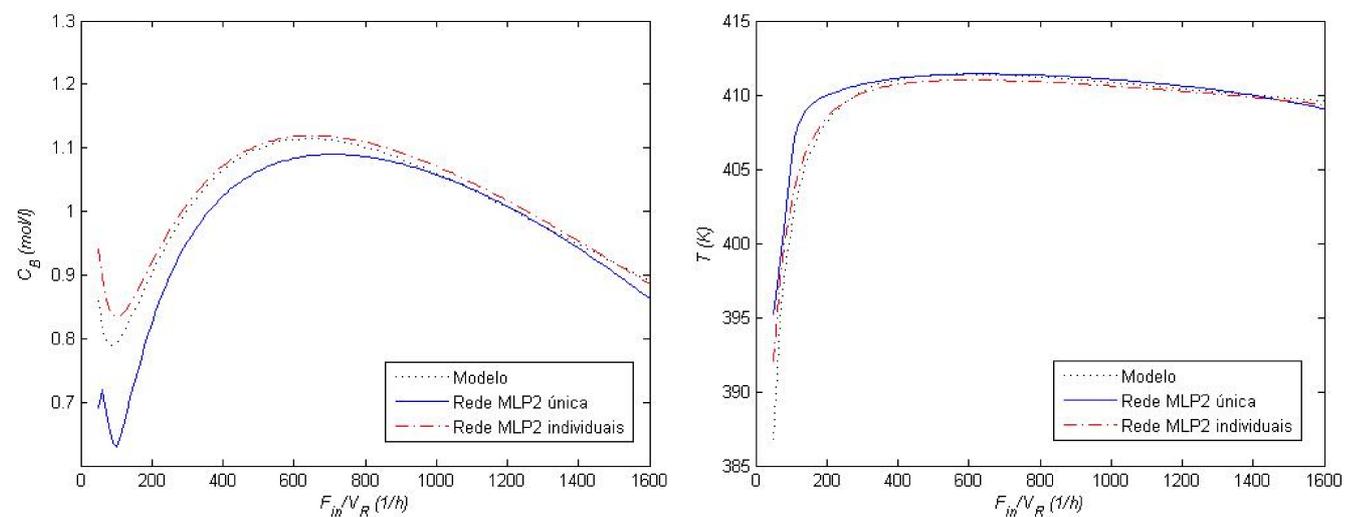


Figura 49 – Comportamento estacionário do processo considerando as redes com tempo de amostragem de 0,008h.

Tabela 19 – Comparação dos resultados das redes únicas e individuais para cada tempo de amostragem.

Tempo de amostragem (h)	Tipo de rede	$\sum E^2 / N(C_B)$	$\sum E^2 / N(T)$
0,002	Única	$6,80 \times 10^{-3}$	0,20
	Individual	$2,35 \times 10^{-4}$	4,34
0,004	Única	$2,30 \times 10^{-3}$	1,87
	Individual	$4,14 \times 10^{-4}$	1,53
0,008	Única	$1,80 \times 10^{-3}$	1,23
	Individual	$2,55 \times 10^{-4}$	0,49

Pelos resultados das Figuras 47 a 49, e da Tabela 19 é possível notar que tanto as redes únicas como as redes individuais foram capazes de prever bem o comportamento estacionário do processo, porém as redes únicas apresentaram maiores desvios em relação aos valores reais, enquanto nas redes individuais os desvios observados são praticamente insignificantes, com exceção da faixa inicial de vazões estudada.

Com relação aos tempos de amostragem, não foi possível identificar diferenças muito significativas na predição do comportamento no estado estacionário de cada rede.

Para a avaliação dos controladores, foram utilizados somente as redes MLP com 2 dados atrasados, e, a princípio, todos os tempo de amostragem foram considerados, devido as pequenas diferença encontradas.

6 APLICAÇÃO DO CONTROLE PREDITIVO NÃO LINEAR

Este capítulo apresenta o estudo do controlador preditivo não linear multivariável baseado em redes neurais aplicado ao reator CSTR com cinética de Van de Vusse. Para comparação e avaliação de possíveis influências da predição por redes neurais no desempenho dos controladores, foram projetados também controladores não lineares com predição pelas próprias equações diferenciais do processo apresentadas no Item 3.1.

O problema MIMO foi formulado conforme estrutura apresentada na Figura 50. As variáveis controladas são a concentração de B (C_B) e a temperatura do reator (T), já as variáveis manipuladas são a vazão de entrada (F_{in}) e o calor retirado do reator pela camisa (Q_k). As condições da corrente de entrada do reator, concentração de A (C_{Ain}) e temperatura (T_{in}), foram tratadas como distúrbios do processo.

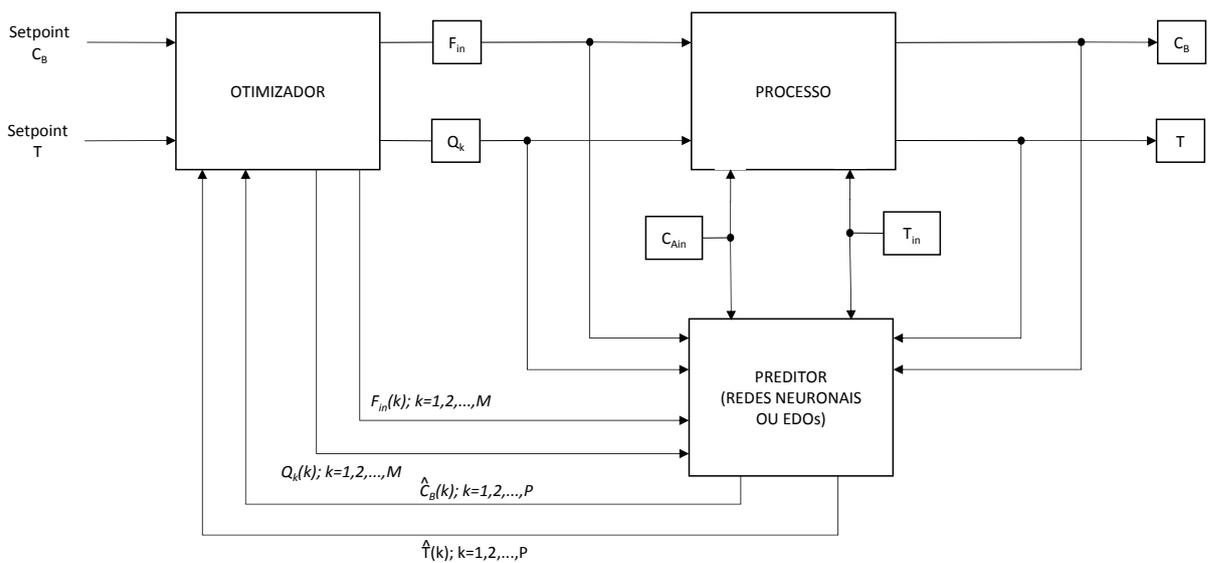


Figura 50 – Estrutura dos controladores NMPC empregados.

Ambos os controladores apresentam basicamente a mesma estrutura, a diferença aparece apenas no cálculo das predições realizadas dentro da função objetivo. A função custo utilizada foi obtida a partir do modelo genérico apresentado na Equação 1, restrita aqui já para o caso multivariável com as variáveis específicas do processo.

$$\begin{aligned}
 J(k) = & w_{C_B} \sum_{j=1}^P [\hat{C}_B(k+j) - r_{C_B}(k+j)]^2 + w_T \sum_{j=1}^P [\hat{T}(k+j) - r_T(k+j)]^2 + \\
 & + \lambda_{F_{in}} \sum_{i=1}^M \Delta F_{in}^2(k+i-1) + \lambda_{Q_k} \sum_{i=1}^M \Delta Q_k^2(k+i-1)
 \end{aligned} \tag{54}$$

Na Equação 54, w_{C_B} e w_T são pesos que podem ser atribuídos ao erro quadrático de cada variável controlada, sendo possível impor uma importância maior a determinada variável. Os parâmetros $\lambda_{F_{in}}$ e λ_{Q_k} são pesos atribuídos às variáveis manipuladas de modo a inibir variações bruscas do sistema. As trajetórias de referência, r_{C_B} e r_T , que podem ser definidas como um mapeamento da rota a ser seguida pela variável controlada até que a nova condição seja estabelecida, seguem um modelo de primeira ordem:

$$r_{C_B}(k+i) = \alpha_{C_B} r_{C_B}(k+i-1) + (1 - \alpha_{C_B}) SP_{C_B} \quad i = 1, \dots, H \tag{55}$$

$$r_T(k+i) = \alpha_T r_T(k+i-1) + (1 - \alpha_T) SP_T \quad i = 1, \dots, H \tag{56}$$

Em que SP_{C_B} e SP_T são os *setpoints* desejados, α_{C_B} e α_T são parâmetros de ajuste. Caso a trajetória de referência seja o próprio *setpoint* em todo o horizonte de predição, o parâmetro $\alpha_j = 0$.

Conforme exposto por Montanheiro (2004), em função da dependência de uma representação matemática interna do processo, o desempenho do controlador pode ser limitado devido às incertezas no modelo e da metodologia empregada. De Souza Jr. (1993) recomenda a aplicação modelo de distúrbio, que corrige o valor predito com base no erro entre o valor medido e o valor predito no passo imediatamente anterior, vide Equação 57.

$$\begin{aligned}
 d_y(k) &= y(k) - \hat{y}(k | k-1) \\
 \hat{y}^c(k+1) &= \hat{y}(k+1) + d_y(k)
 \end{aligned}
 \tag{57}$$

Para a primeira predição, $d_y(k)$ é calculado e o valor predito é corrigido (indicado pelo subscrito d). As predições seguintes também são corrigidas supondo $d_y(k)$ para todo horizonte de predição. As predições corrigidas são então utilizadas na função objetivo.

Após definição da função objetivo, o problema de controle passa pela otimização da mesma a cada instante de controle, sujeita a algumas restrições do processo. As únicas restrições utilizadas foram os limites das variáveis manipuladas, baseados no trabalho de Trierweiler (1997). Não foram considerados limites máximos de variações, pois os mesmos já são tratados dentro implicitamente da função objetivo através dos parâmetros $\lambda_{F_{in}}$ e λ_{Q_k} . Os limites das variáveis manipuladas são os mesmos utilizados no controle PID multimalhas e apresentados na Tabela 9.

A modelagem dos controladores foi feita no MATLAB® (R2010a), utilizando a rotina *fmincon* (método de otimização *interior-point*), para otimização não linear com restrições.

Para estudo inicial dos controladores não lineares, foram utilizados dois cenários de alteração de SP. Em ambos o processo partiu de condição operacional estável bem próxima à região de inversão de ganho sendo submetido, no primeiro a uma redução de SP de 0,1 mol/l e no segundo a aumento no SP de mesmo valor. Estes mesmos cenários foram avaliados com os controladores PID no Capítulo 4.

No primeiro cenário espera-se que os controladores NMPC sejam capazes de levar o processo ao novo SP de maneira mais suave que os controladores PID. Já no segundo cenário, como o SP exigido é inatingível, espera-se que os controladores NMPC mantenham o processo estável no valor mais próximo possível do SP exigido, o que não foi possível com os controladores PID, conforme visto no Capítulo 4.

6.1 Predição por Redes Neurais

Conforme resultados do Capítulo 5, as redes lineares e MLP com um dado atrasado não foram capazes de prever bem o comportamento dinâmico do sistema ao longo de um horizonte de predição razoável, e portanto foram descartadas do estudo.

Os diferentes tempos de amostragem utilizados (0,002, 0,004 e 0,008 h) não apresentaram diferenças relevantes nos resultados na identificação do processo, e portanto as redes MLP com 2 dados atrasados de cada tempo de amostragem foram utilizadas para estudo.

Apesar das redes MLP individuais apresentarem melhores resultados na identificação do sistema, as redes MLP únicas também foram utilizadas para teste, já que resultam em uma menor quantidade de parâmetros, e, conseqüentemente, diminuem os esforços computacionais de otimização, podendo melhorar o desempenho dos controladores.

Primeiramente, de modo a avaliar a influência do tempo de amostragem, foram feitas simulações com os três diferentes tempos de amostragem, mantendo os parâmetros dos controladores constantes ($w_{C_B} = w_T = 1$; $\lambda_{F_m} = 10^{-5}$; $\lambda_{Q_k} = 10^{-7}$; $\alpha_{C_B} = \alpha_T = 1$; $M = 5$), com exceção do horizonte de predição que foi variado de acordo com o tempo de amostragem, de forma a utilizar a predição no mesmo horizonte de tempo em cada caso ($P = 40$ para 0,002 h; $P = 20$ para 0,004 h; $P = 10$ para 0,008 h) . Os resultados para redes únicas são apresentados nas Figuras 51 e 52.

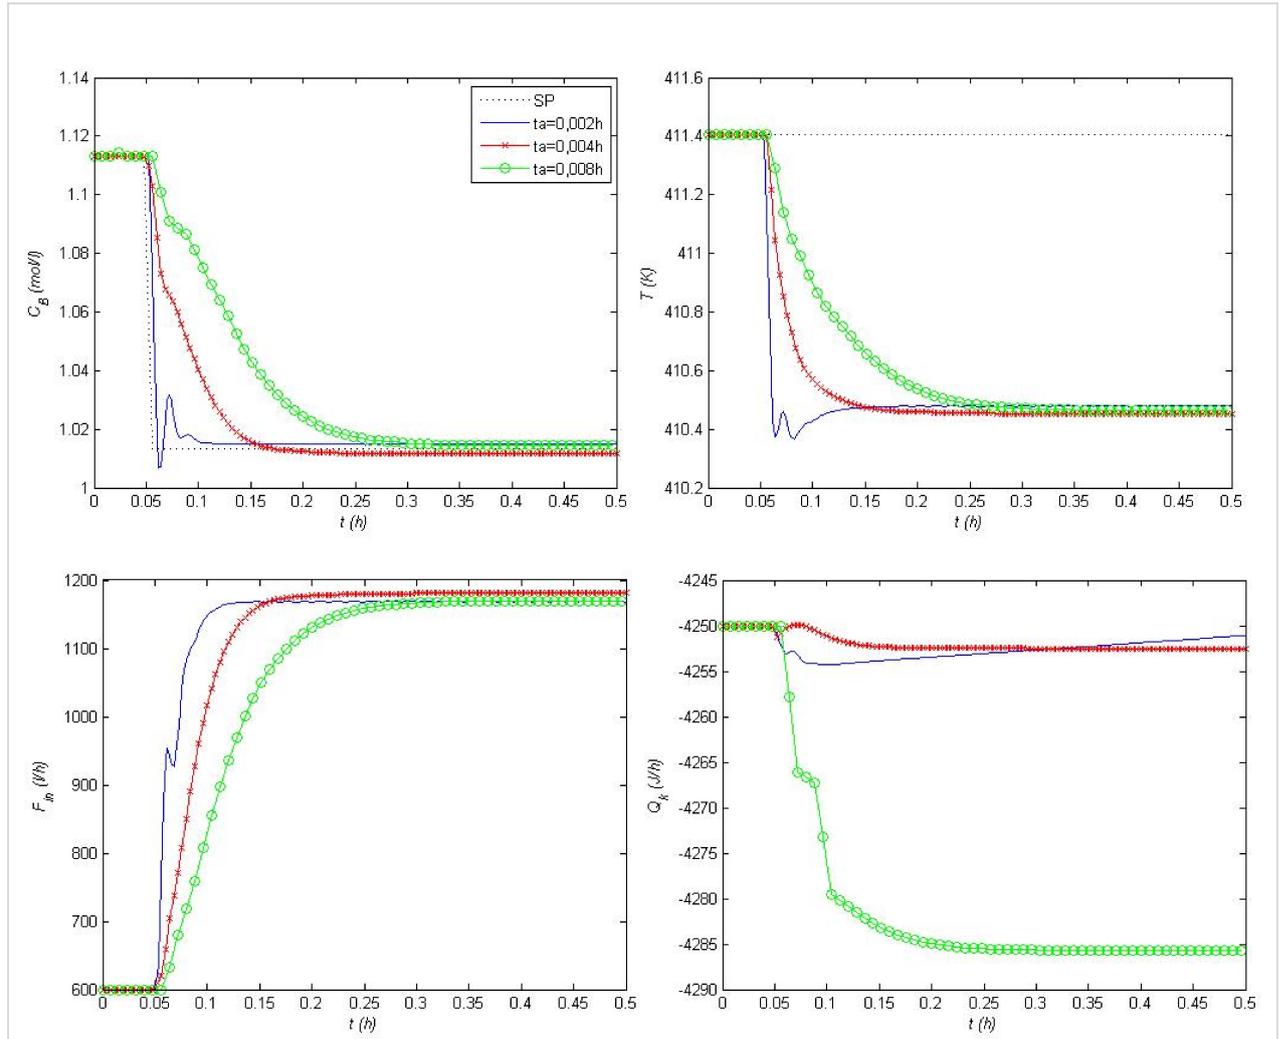


Figura 51 – NMPC com redes MLP únicas – Cenário de redução de SP de C_B .

Os primeiros resultados encontrados nas Figuras 51 e 52 apresentam diferenças significativas entre os tempo de amostragem utilizados, que não foram observados na identificação do modelo.

Nas simulações de redução de SP, pode ser observado que o tempo para assentamento da resposta tende a ser menor quanto menor for o tempo de amostragem. Na simulação com o tempo de amostragem de 0,002h o sistema atinge o valor final em cerca de 0,1h, enquanto que no tempo de amostragem de 0,008h, o estado estacionário final é alcançado em cerca de 0,3h. Essa diferença ocorre basicamente devido a maior quantidade de ações de controle realizadas para tempo de amostragem menores, ou seja, a cada uma ação de controle para o tempo de amostragem de 0,008h, o controlador com tempo de amostragem de 0,002h realiza 4 ações de controle.

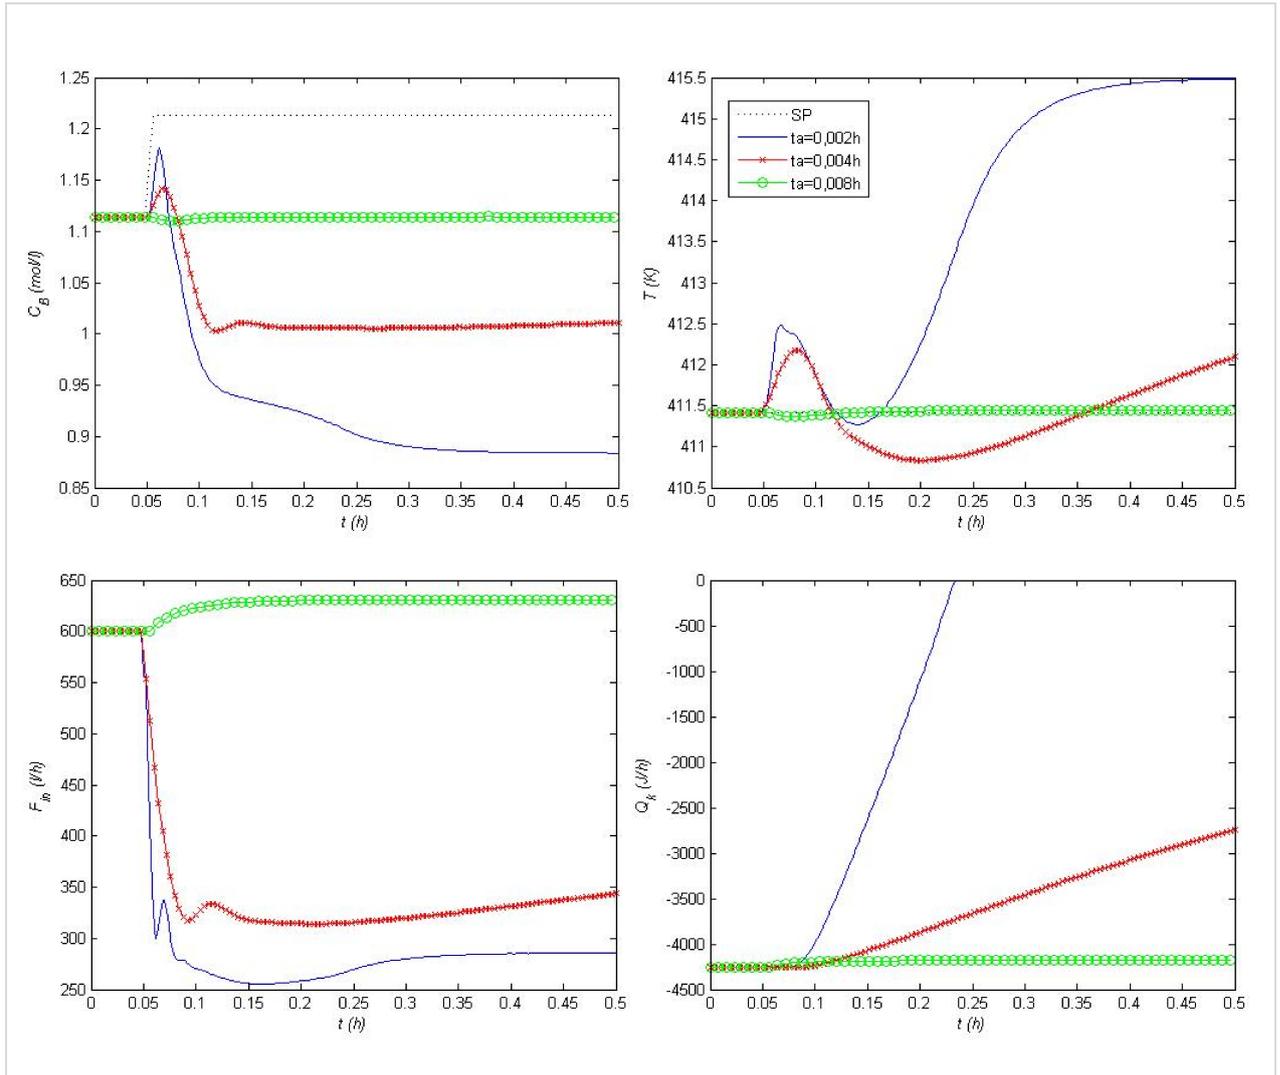


Figura 52 – NMPC com redes MLP únicas – Cenário de aumento de SP de C_B .

Outra diferença importante que pode ser notada, é que quanto maior o tempo de amostragem, mais suavemente o sistema é levado até o novo estado estacionário, já que em tempos de amostragens muito baixos as dinâmicas rápidas do sistema tendem a influenciar bastante nas ações de controle.

Pode ser notada também a presença de alguns *offsets* na simulações, que são intensificados nos tempos de amostragens mais baixos. No maior tempo de amostragem os *offsets* já mostram-se insignificantes. Esse resultado parece evidenciar problemas nos modelos para tempos de amostragens baixos.

Nas simulações de aumento de SP, os resultados foram ainda mais discrepantes. Nas simulações com tempo de amostragem 0,002 h e 0,004 h o

sistema mostrou-se instável, enquanto que no tempo de amostragem de 0,008 h o sistema estabilizou-se. O resultado para o tempo de amostragem de 0,008h foi conforme esperado, conseguindo manter o sistema estável o mais próximo possível do SP desejado.

As mesmas simulações foram feitas com as redes individuais, e são apresentadas nas Figuras 53 e 54.

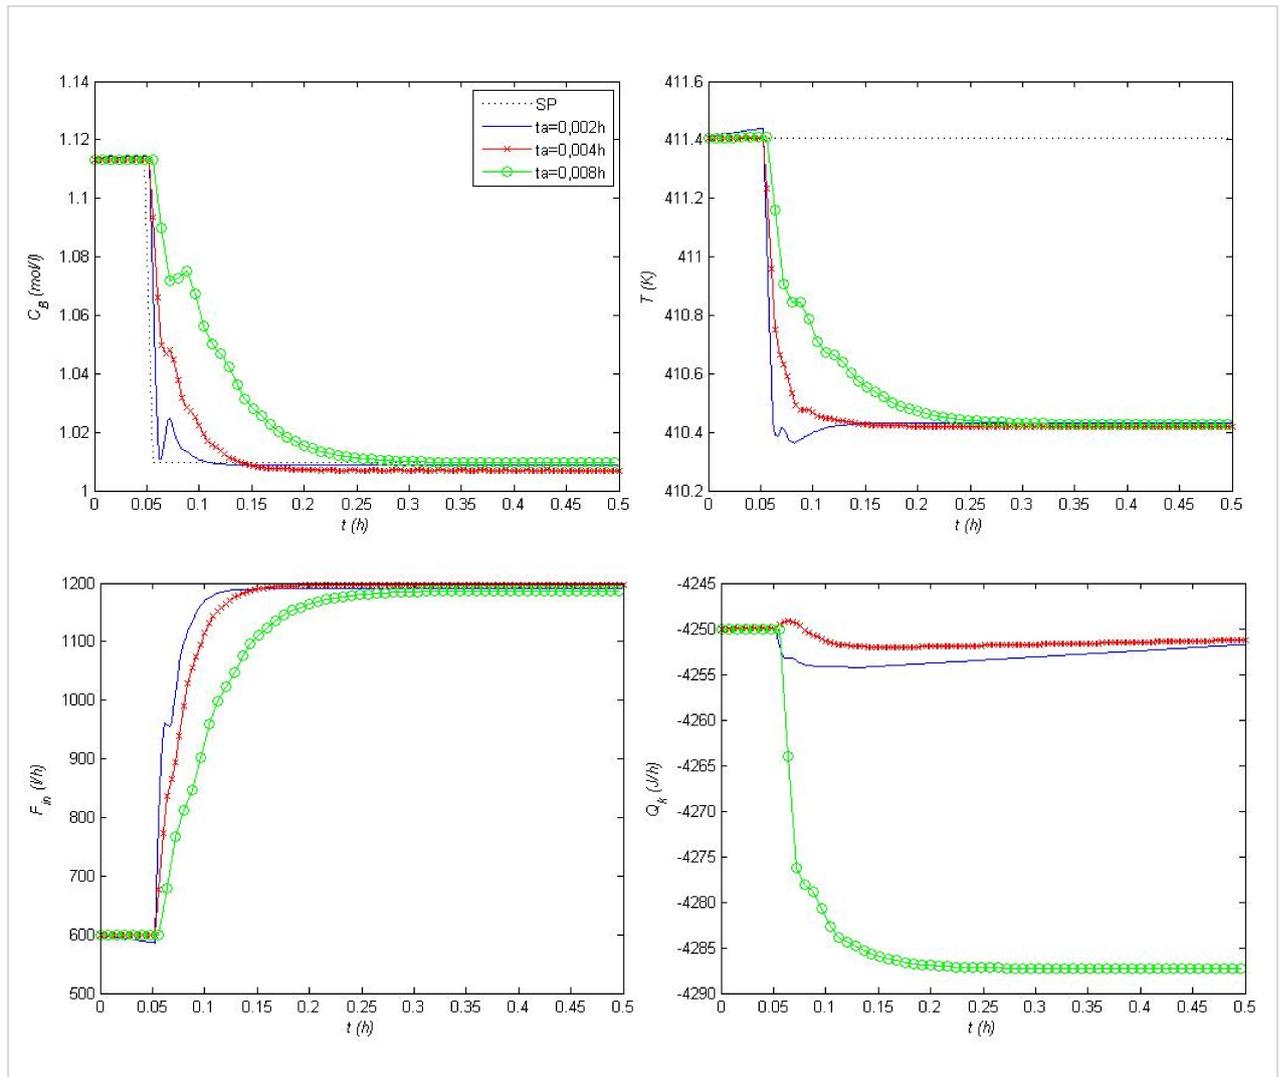


Figura 53 – NMPC com redes MLP individuais – Cenário de redução de SP de C_B .

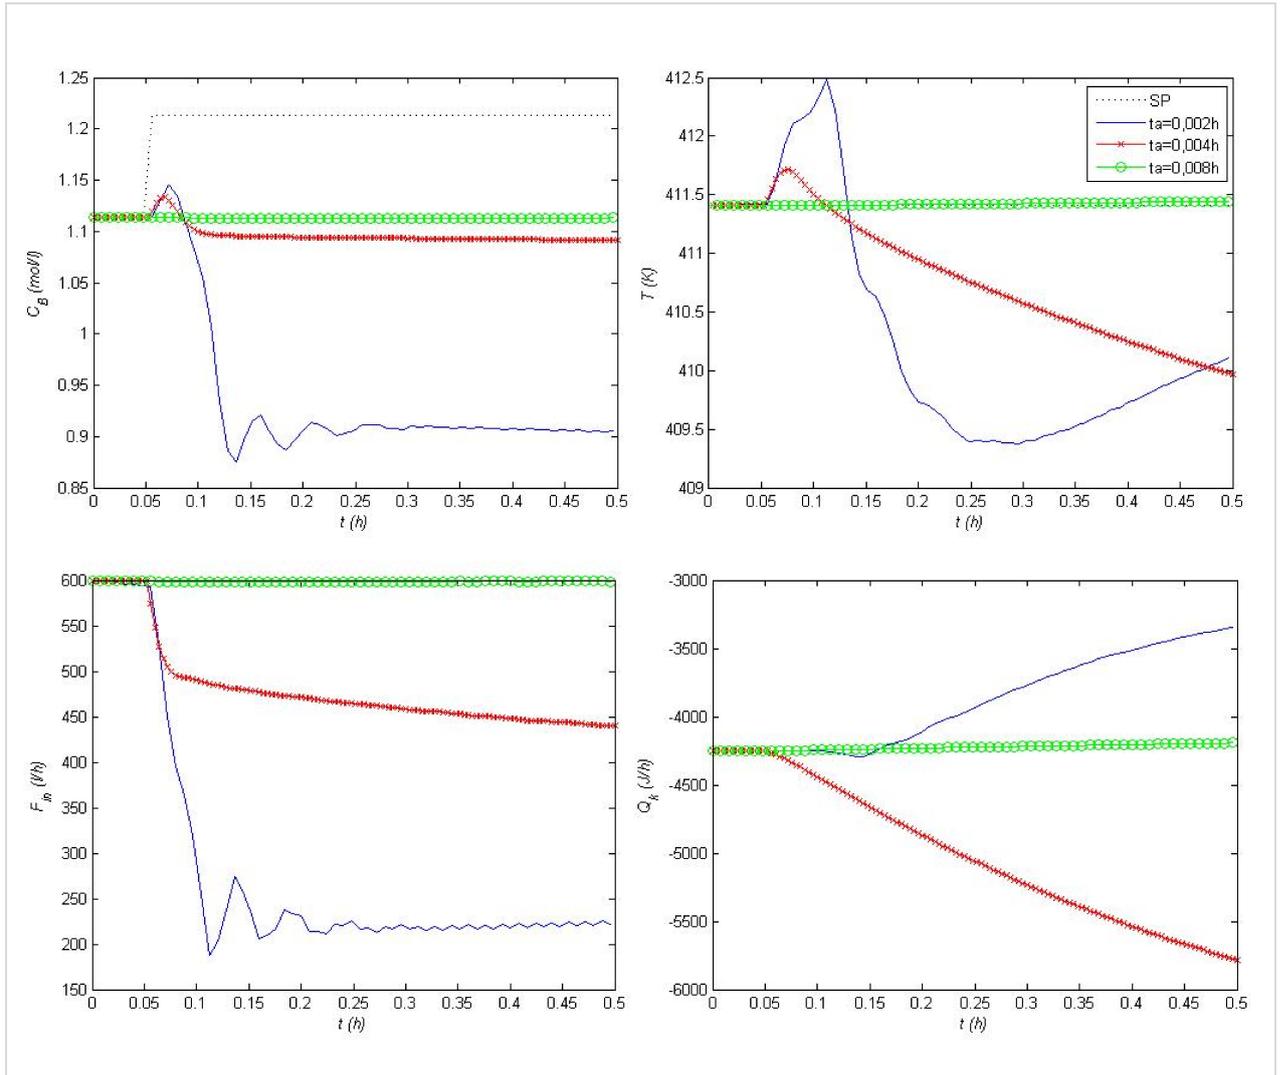


Figura 54 – NMPC com redes MLP individuais – Cenário de aumento de SP de C_B .

Os resultados encontrados para as redes individuais possuem características parecidas com os resultados das redes únicas. Porém, é possível notar uma redução nos *offsets* gerados devido à melhora na qualidade do modelo, a qual foi evidenciada no Capítulo 5.

Pelos resultados encontrados, tanto com as redes únicas como com as redes individuais, os tempos de amostragem 0,002h e 0,004h parecem não serem adequados para controle do sistema.

A importância dos demais parâmetros nos resultados foi estudada de forma mais profunda no item 6.3.

6.2 Predição pelas Equações Diferenciais

Para efeito de comparação com os resultados encontrados com controladores preditivos baseados em redes neurais, foram modelados controladores preditivos com predição feita pelas próprias equações diferenciais do sistema. Dessa forma foi possível estudar a influência da qualidade do modelo de redes neurais no desempenho do controlador, já que a predição pelas EDOs pode ser considerada perfeita.

A estrutura do controlador é semelhante aos controladores baseados em redes neurais. A única mudança é na obtenção da predição do modelo, nesse caso realizado pela resolução das EDOs do sistema ao longo do horizonte de predição. No caso das EDOs apenas um dado atrasado é utilizado como condição inicial para o sistema de equações diferenciais.

Apesar da predição ser considerada perfeita, a resolução de um sistema de equações não linear a cada instante de amostragem, exige um esforço computacional elevado para o controlador, podendo interferir significativamente nos resultados.

Uma solução para diminuir os esforços computacionais e conseqüentemente o tempo de simulação, é fornecer a matriz jacobiana diretamente para o controlador, evitando que a mesma seja calculada numericamente a cada iteração do otimizador em cada instante de amostragem. Dessa forma, a matriz jacobiana do sistema (\mathbf{J}) foi obtida de forma analítica a partir das EDOs.

$$\mathbf{J} = \begin{bmatrix} \frac{\partial}{\partial C_A} \left(\frac{\partial C_A}{\partial t} \right) & \frac{\partial}{\partial C_B} \left(\frac{\partial C_A}{\partial t} \right) & \frac{\partial}{\partial T} \left(\frac{\partial C_A}{\partial t} \right) & \frac{\partial}{\partial T_k} \left(\frac{\partial C_A}{\partial t} \right) \\ \frac{\partial}{\partial C_A} \left(\frac{\partial C_B}{\partial t} \right) & \frac{\partial}{\partial C_B} \left(\frac{\partial C_B}{\partial t} \right) & \frac{\partial}{\partial T} \left(\frac{\partial C_B}{\partial t} \right) & \frac{\partial}{\partial T_k} \left(\frac{\partial C_B}{\partial t} \right) \\ \frac{\partial}{\partial C_A} \left(\frac{\partial T}{\partial t} \right) & \frac{\partial}{\partial C_B} \left(\frac{\partial T}{\partial t} \right) & \frac{\partial}{\partial T} \left(\frac{\partial T}{\partial t} \right) & \frac{\partial}{\partial T_k} \left(\frac{\partial T}{\partial t} \right) \\ \frac{\partial}{\partial C_A} \left(\frac{\partial T_k}{\partial t} \right) & \frac{\partial}{\partial C_B} \left(\frac{\partial T_k}{\partial t} \right) & \frac{\partial}{\partial T} \left(\frac{\partial T_k}{\partial t} \right) & \frac{\partial}{\partial T_k} \left(\frac{\partial T_k}{\partial t} \right) \end{bmatrix} \quad (58)$$

Em que:

$$\frac{\partial}{\partial C_A} \left(\frac{\partial C_A}{\partial t} \right) = -\frac{F}{V_R} - k_1(T) - 2k_3(T)C_A; \quad \frac{\partial}{\partial C_B} \left(\frac{\partial C_A}{\partial t} \right) = 0;$$

$$\frac{\partial}{\partial T} \left(\frac{\partial C_A}{\partial t} \right) = -C_A \frac{dk_1(T)}{dT} - C_A^2 \frac{dk_3(T)}{dT}; \quad \frac{\partial}{\partial T_k} \left(\frac{\partial C_A}{\partial t} \right) = 0;$$

$$\frac{\partial}{\partial C_A} \left(\frac{\partial C_B}{\partial t} \right) = k_1(T); \quad \frac{\partial}{\partial C_B} \left(\frac{\partial C_B}{\partial t} \right) = -\frac{F}{V_R} - k_2(T);$$

$$\frac{\partial}{\partial T} \left(\frac{\partial C_B}{\partial t} \right) = C_A \frac{dk_1(T)}{dT} - C_B \frac{dk_2(T)}{dT}; \quad \frac{\partial}{\partial T_k} \left(\frac{\partial C_B}{\partial t} \right) = 0;$$

$$\frac{\partial}{\partial C_A} \left(\frac{\partial T}{\partial t} \right) = \frac{-k_1(T)\Delta H_1}{\rho C_B} - \frac{2C_A k_3(T)\Delta H_3}{\rho C_B}; \quad \frac{\partial}{\partial C_B} \left(\frac{\partial T}{\partial t} \right) = \frac{-k_2(T)\Delta H_2}{\rho C_B}$$

$$\frac{\partial}{\partial T} \left(\frac{\partial T}{\partial t} \right) = -\frac{F}{V_R} - \frac{k_w A_R}{\rho C_B V_R} - \frac{C_A \Delta H_1}{\rho C_B} \frac{dk_1(T)}{dT} - \frac{C_B \Delta H_2}{\rho C_B} \frac{dk_2(T)}{dT} + \frac{C_A^2 \Delta H_3}{\rho C_B} \frac{dk_3(T)}{dT};$$

$$\frac{\partial}{\partial T} \left(\frac{\partial T}{\partial t} \right) = \frac{k_w A_R}{\rho C_B V_R}; \quad \frac{\partial}{\partial C_A} \left(\frac{\partial T_k}{\partial t} \right) = 0; \quad \frac{\partial}{\partial C_B} \left(\frac{\partial T_k}{\partial t} \right) = 0;$$

$$\frac{\partial}{\partial T} \left(\frac{\partial T_k}{\partial t} \right) = \frac{k_w A_R}{m_k C p_k}; \quad \frac{\partial}{\partial T_k} \left(\frac{\partial T_k}{\partial t} \right) = -\frac{k_w A_R}{m_k C p_k};$$

$$\frac{dk_i(T)}{dT} = -\frac{k_i^0 E_i}{T^2} \exp\left(\frac{E_i}{T}\right) \quad i=1, 2 \text{ e } 3$$

Em testes preliminares, o simples fornecimento da matriz jacobiana representou uma redução de cerca de 40% no tempo da otimização a cada tempo de amostragem.

Os mesmos cenários de alteração de SP foram simulados utilizando o controlador preditivo com previsões pelas EDOs e são apresentados nas Figuras 55 e 56.

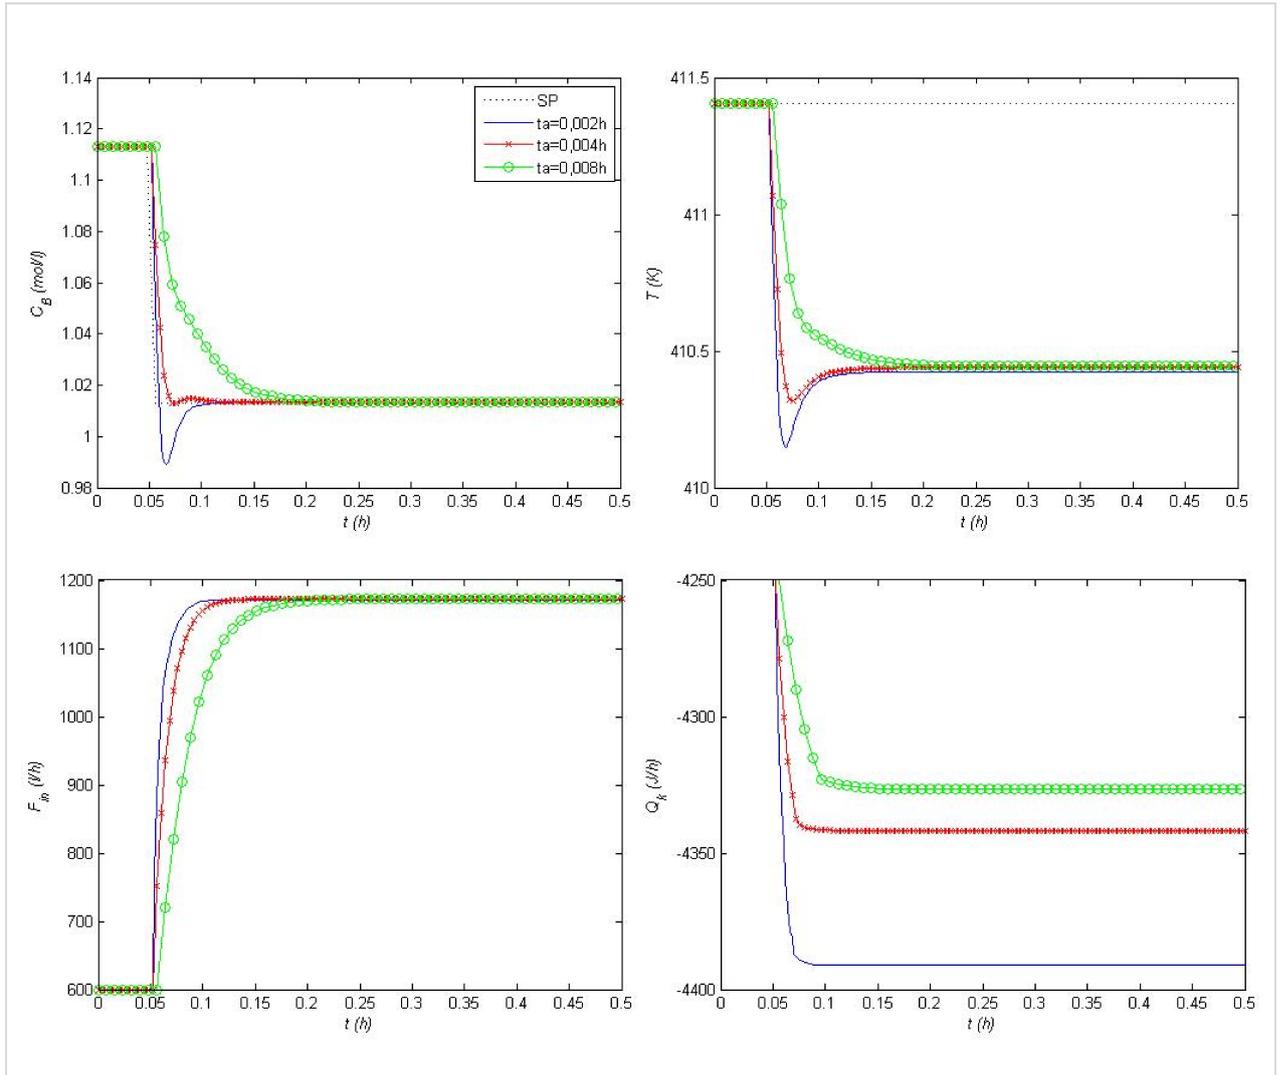


Figura 55 – NMPC com redes MLP individuais – Cenário de redução de SP de C_B .

O comportamento dos controladores com previsão pelas EDOs é semelhante aos controladores baseados em redes neuronais, conforme pode ser observado nas Figuras 55 e 56. Quanto menor o tempo de amostragem, mais rápido o processo é levado ao novo estado estacionário.

Assim como nos controladores de redes neuronais, também é possível notar a presença de *offsets* em relação ao SP da temperatura do reator, portanto não sendo problema de previsão dos modelos, já que as previsões realizadas pelas EDOs podem ser consideradas perfeitas. Aparentemente, esse problema parece ser devido à diferença de ordem de grandeza entre as variações observadas nas variáveis. Uma variação de 0,1 mol/l na concentração de B representa 10%, enquanto uma variação de 1°C na temperatura representa apenas aproximadamente

0,2%. Esse problema foi solucionado através de ajustes nos pesos das variáveis controladas, realizado no Item 6.3.1 adiante.

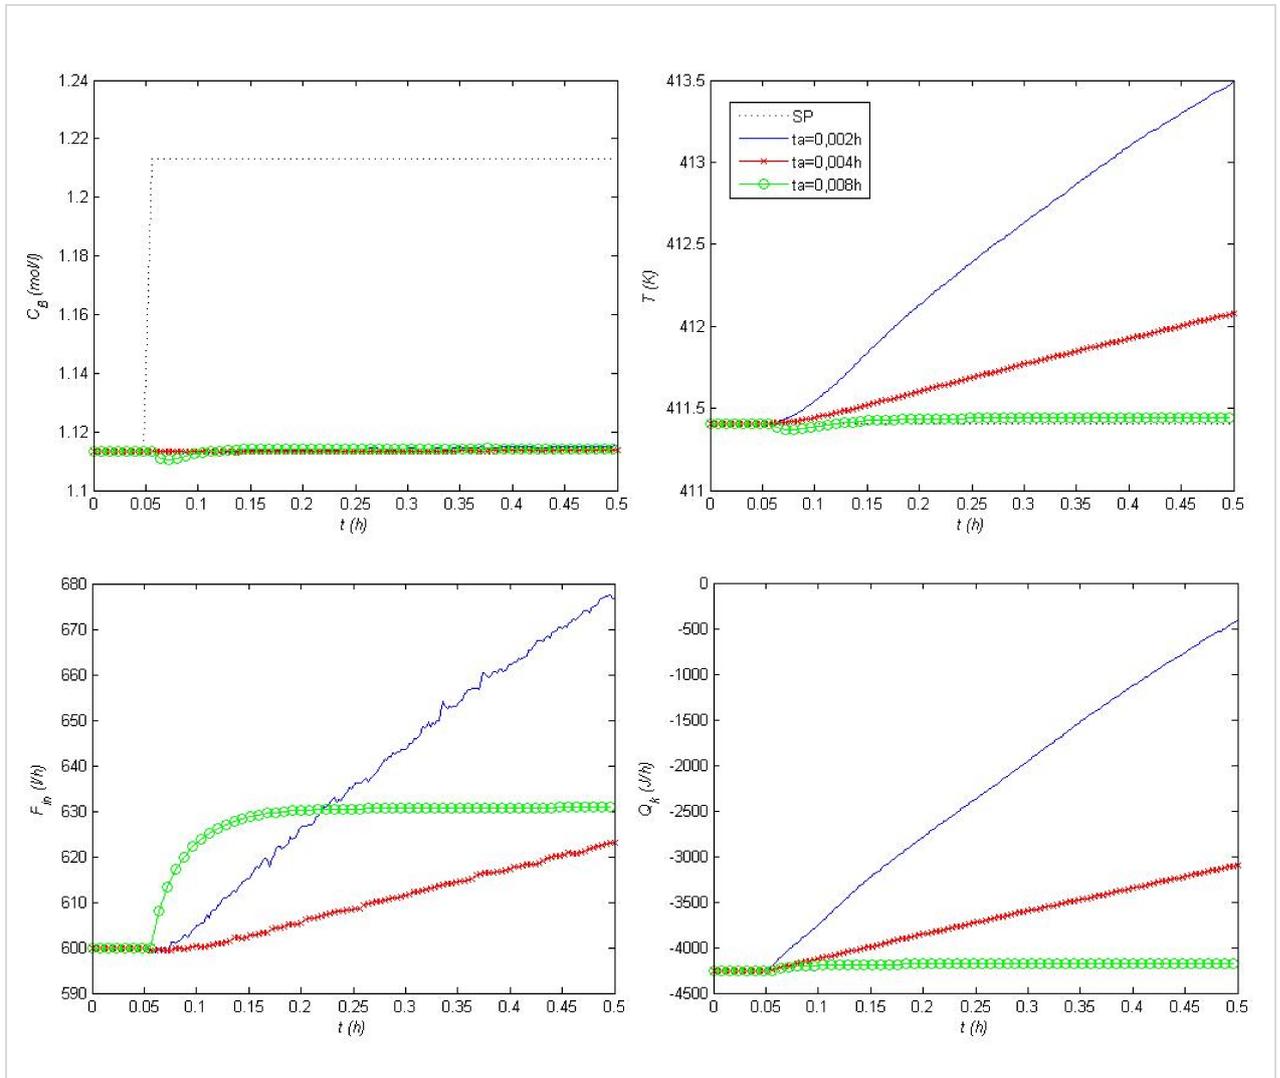


Figura 56 – NMPC com redes MLP individuais – Cenário de aumento de SP de C_B .

No cenário de aumento de SP de C_B , em casos com tempo de amostragem de 0,002 e 0,004 h, apesar de aparentemente conseguir manter a concentração de B no seu valor máximo, as ações de controle não foram zeradas mesmo após um tempo de simulação de 0,5 h, e conseqüentemente as variáveis manipuladas continuaram sendo aumentadas. Já para o tempo de amostragem de 0,008 h, o sistema estabilizou-se no ponto de máxima concentração de B. Essa característica também foi observada nos modelos de redes neuronais.

Analisando os resultados do cenário de redução de SP de C_B , o tempo de amostragem de 0,004 h parece ser o mais adequado, porém, nas simulações do cenário de aumento de SP de C_B , mesmo considerando o mesmo intervalo de tempo de predição, todos os controladores com esse tempo mostraram-se instáveis.

Outro fator importante é a diferença no tempo de otimização necessária a cada tempo de amostragem, que chega a ser até duas vezes superior nos controladores com tempo de amostragem de 0,004 h em relação aos controladores com 0,008 h.

Conforme já observado anteriormente por Secchi *et al.* (2001), nota-se que o tempo de amostragem representa um ponto crucial para bom funcionamento dos controladores, podendo levar o mesmo à instabilidade, conforme obtido para os tempos de amostragem mais baixos (0,002 e 0,004 h) nos cenários de aumento de SP de C_B .

De maneira geral, analisando a relação desempenho e esforço computacional, o tempo de amostragem de 0,008 h mostra-se mais adequado ao controle do sistema, apresentando bom desempenho e esforço computacional compatível com seu intervalo de amostragem.

6.3 Avaliação da Influência dos Parâmetros

Conforme os resultados obtidos nos itens 6.1 e 6.2, os controladores preditivos não lineares modelados apresentaram-se capazes de controlar o processo, mesmo na região crítica de inversão de ganho.

Neste item, foi dada maior atenção aos estudos dos parâmetros de ajustes dos controladores. Neste estudo, foi utilizado o modelo baseado nas EDOs, que por ser um modelo perfeito, não apresenta possíveis falhas no modelo que possam mascarar a influência dos parâmetros dos controladores. O tempo de amostragem escolhido foi o de 0,008 h por apresentar resultados melhores em todos os casos estudados.

6.3.1 Pesos das Variáveis Controladas

Para avaliação da razão entre os pesos das variáveis controladas ($R_w = w_T/w_{C_B}$), foram feitas simulações do cenário de redução de SP com R_w variando de 1 a 400. Os resultados são apresentados na Figura 57.

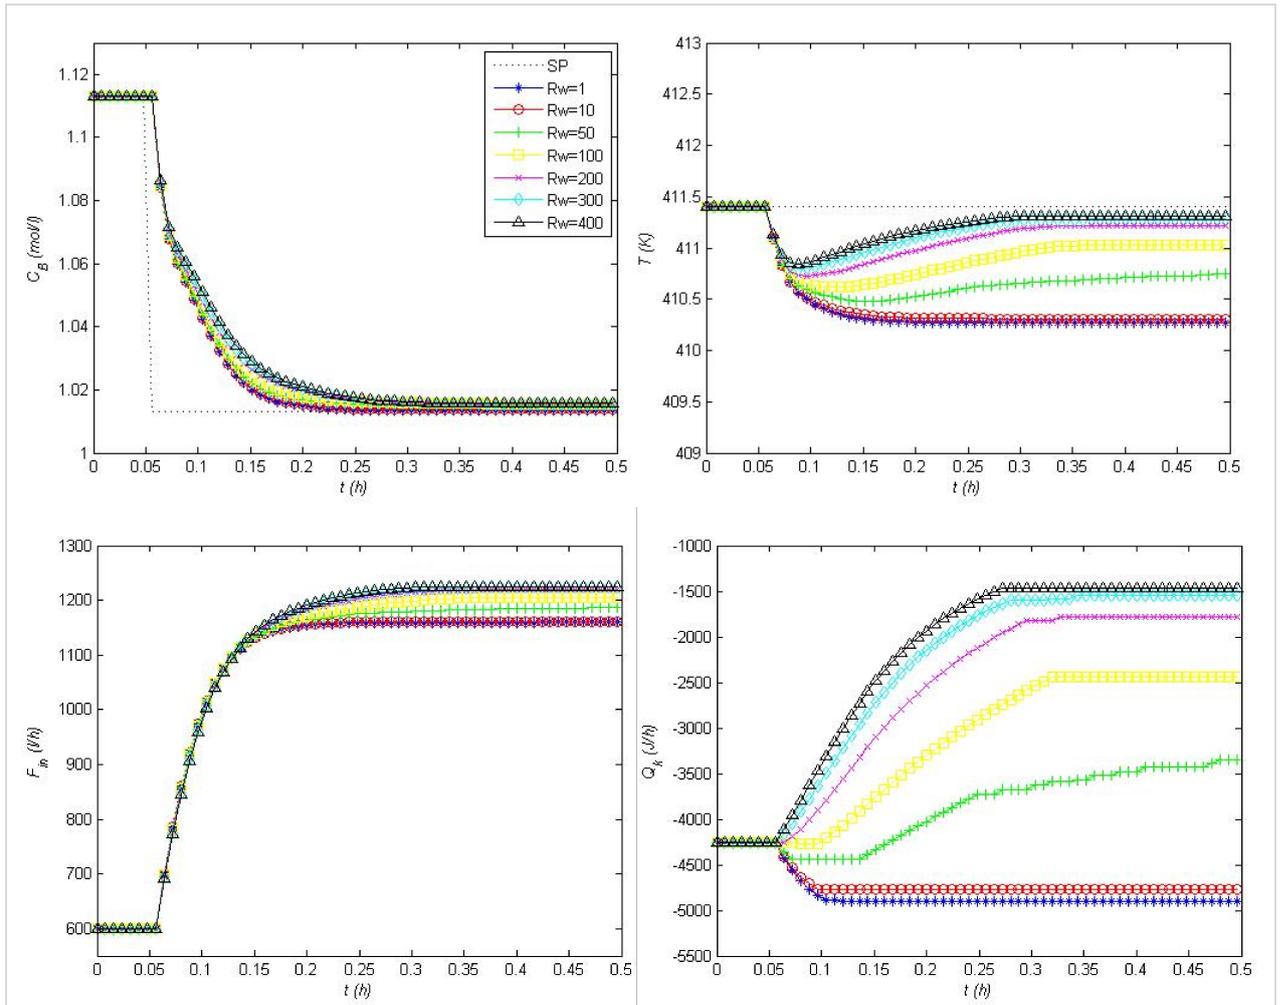


Figura 57 – Avaliação da razão entre os pesos das variáveis controladas ($R_w = w_T/w_{C_B}$).

Conforme pode ser observado, para valores de R_w inferiores a 200, o novo SP de concentração de B é atingido, porém o controlador não consegue manter a temperatura do reator no mesmo SP. Para valores superiores a 200, inclusive, o controlador consegue manter o SP de temperatura, sem prejudicar sua performance de alcance do novo SP de concentração de B.

Esses resultados já eram esperados devido à diferença percentual das alterações nas duas variáveis controladas, conforme descrito no item anterior.

6.3.2 Pesos das Variáveis Manipuladas

A influência dos pesos das variáveis manipuladas no desempenho do controlador também foi investigada utilizando como base o cenário de redução de SP. Os resultados são apresentados na Figura 58.

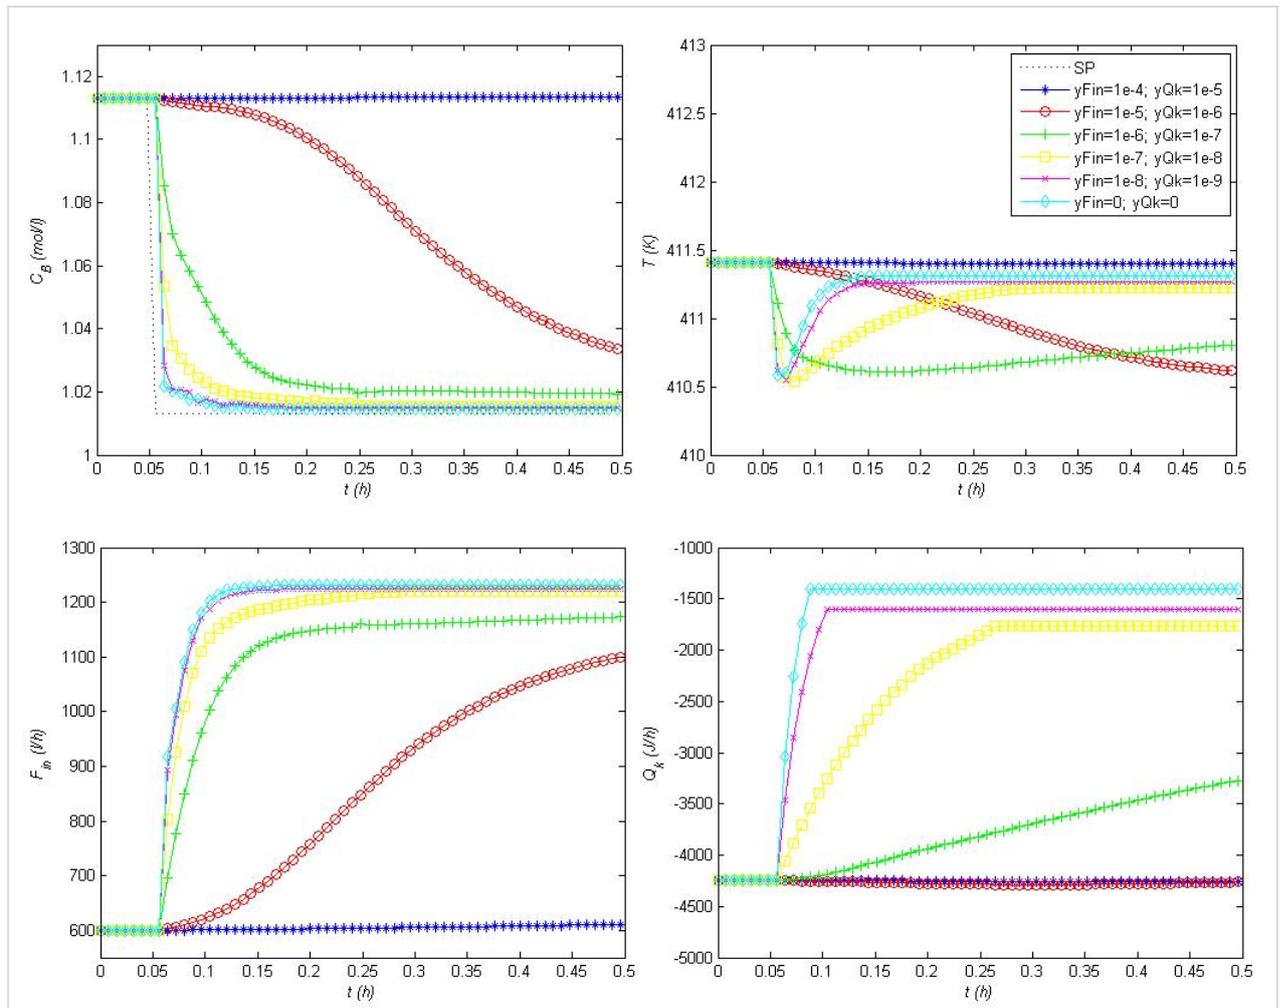


Figura 58 – Influência dos pesos das variáveis manipuladas ($\lambda_{F_{in}}$ e λ_{Q_k}).

Os pesos das variáveis manipuladas têm grande importância na suavização das ações de controle, conforme pode ser observado na Figura 58. Para valores de $\lambda_{F_{in}}$ e λ_{Q_k} maiores que 10^{-6} e 10^{-7} , respectivamente, a limitação às ações de controles é tão forte que impede que a nova condição desejada do processo seja atingida. Para valores muito inferiores, não há nenhuma limitação nas ações de controle, que no caso avaliado não apresentaram problema para desempenho dos controladores, porém poderiam instabilizar o controlador em outros cenários, principalmente nos casos sem utilização de modelo perfeito (redes neurais).

Dessa forma, os valores julgados mais adequados para os parâmetros $\lambda_{F_{in}}$ e λ_{Q_k} são 10^{-6} e 10^{-8} , respectivamente, por apresentarem alguma limitação às ações de controle sem prejudicar o desempenho do controlador na obtenção do novo estado desejado.

6.3.3 Horizontes de Predição e Controle

O cenário de redução de SP também foi utilizado para avaliar a influência dos horizontes de controle e predição. Nas simulações da Figura 59, o horizonte de controle foi mantido constante em 3, enquanto o horizonte de predição foi variado na faixa de 5 a 50. Os horizontes de predição pequenos (5 e 10) mostraram-se suficientes para obtenção do novo SP de C_B , porém, insuficientes para manutenção do SP da temperatura do reator. Para os horizontes superiores a 20, inclusive, ambos os SP foram atingidos.

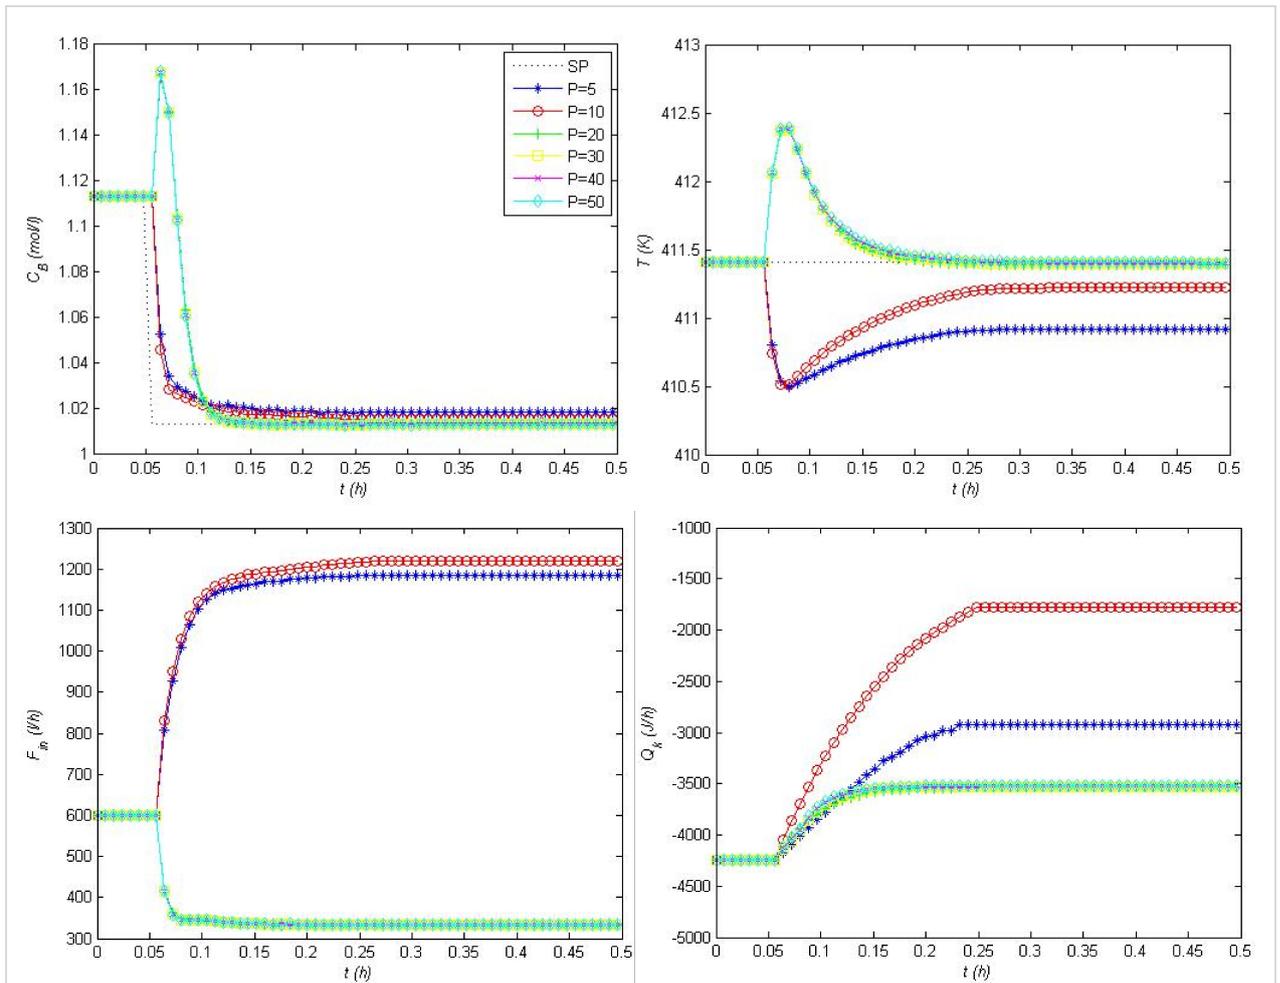


Figura 59 – Influência do horizonte de predição (P).

É Interessante observar que o valor do horizonte de predição foi determinante para selecionar para qual região o processo seria levado, lembrando que o ponto de operação inicial é o ponto de concentração de B máxima, ponto onde ocorre a inversão de ganho.

Nas simulações da Figura 60, o horizonte de controle foi aumentado gradativamente, enquanto o horizonte de predição foi mantido constante em 20. No caso com menor horizonte de controle ($M = 1$), os SPs foram atingidos, apesar de apresentar maior agressividade. Para horizontes de controle acima de 3, os resultados foram semelhantes, observando porém, um aumento significativo no tempo de simulação com o aumento de M , pelo aumento linear do número de variáveis de otimização.

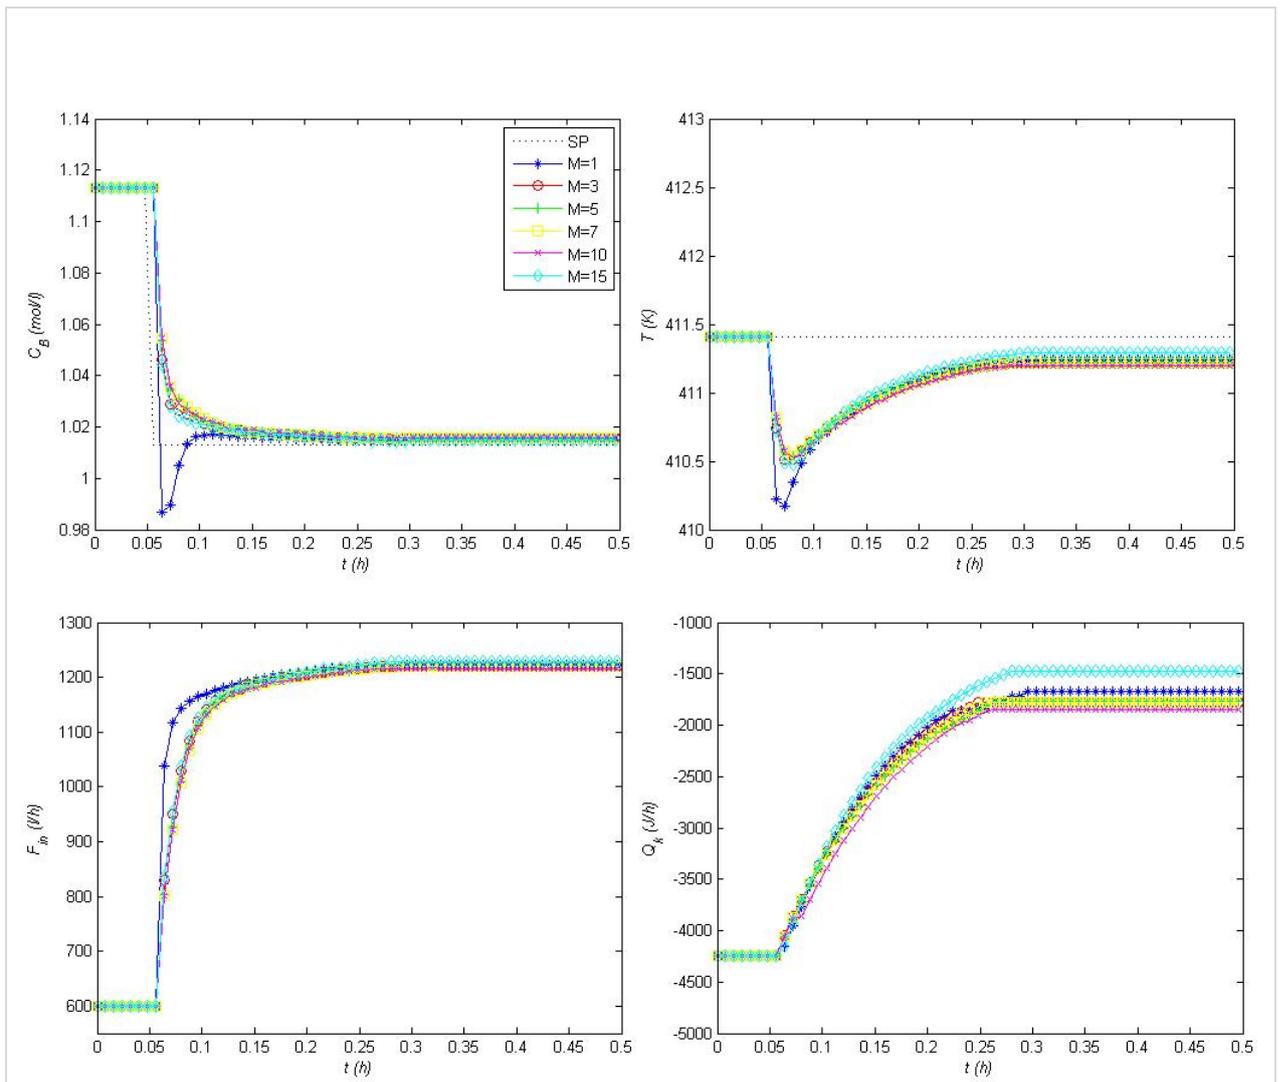


Figura 60 – Influência do horizonte de controle (M).

6.4 Comparação dos Resultados

Para avaliação final, além dos cenários de alterações de SP já estudados, foram simulados novos cenários para comparação entres os controladores preditivos não lineares (Redes Neurais e EDOs) e os controladores PID tradicionais. A Tabela 20 apresenta os cenários utilizados para comparação.

Tabela 20 – Cenários utilizados para comparação entre os diferentes controladores.

ID	Cenário	Descrição	Figura	Tabela
1	Redução de SP de C_B	Redução de 0,1 mol/l no SP da concentração de B no reator	Figura 61	Tabela 22
2	Aumento de SP de C_B	Aumento de 0,1 mol/l no SP da concentração de B no reator	Figura 62	Tabela 23
3	Redução de SP de T	Redução de 5°C na temperatura do reator	Figura 63	Tabela 24
4	Aumento de SP de T	Aumento de 5°C na temperatura do reator	Figura 64	Tabela 25
5	Perturbação Positiva em C_{Ain}	Perturbação +0,9 mol/l na concentração de A na entrada no reator	Figura 65	Tabela 26
6	Perturbação Negativa em C_{Ain}	Perturbação -1,1 mol/l na concentração de A na entrada no reator	Figura 66	Tabela 27

A partir dos resultados encontrados nas análises das influências dos parâmetros do controlador, os parâmetro apresentados na Tabela 21 foram utilizados em todas simulações, com exceção das simulações com PID tradicional, onde esses parâmetros não são aplicáveis, e foram utilizados os parâmetros de sintonia encontrados no item 4.3.

Tabela 21 – Parâmetros dos controladores preditivos utilizados.

Parâmetro	Valor	Parâmetro	Valor	Parâmetro	Valor
w_{C_B}	1	$\lambda_{F_{in}}$	10^{-6}	P	20
w_T	200	λ_{Q_k}	10^{-8}	M	3

Para auxiliar na análise dos resultados, foram calculados os somatórios dos erros ao quadrado (ISE) e o esforço de manipulação (SU) para cada controlador em cada cenário.

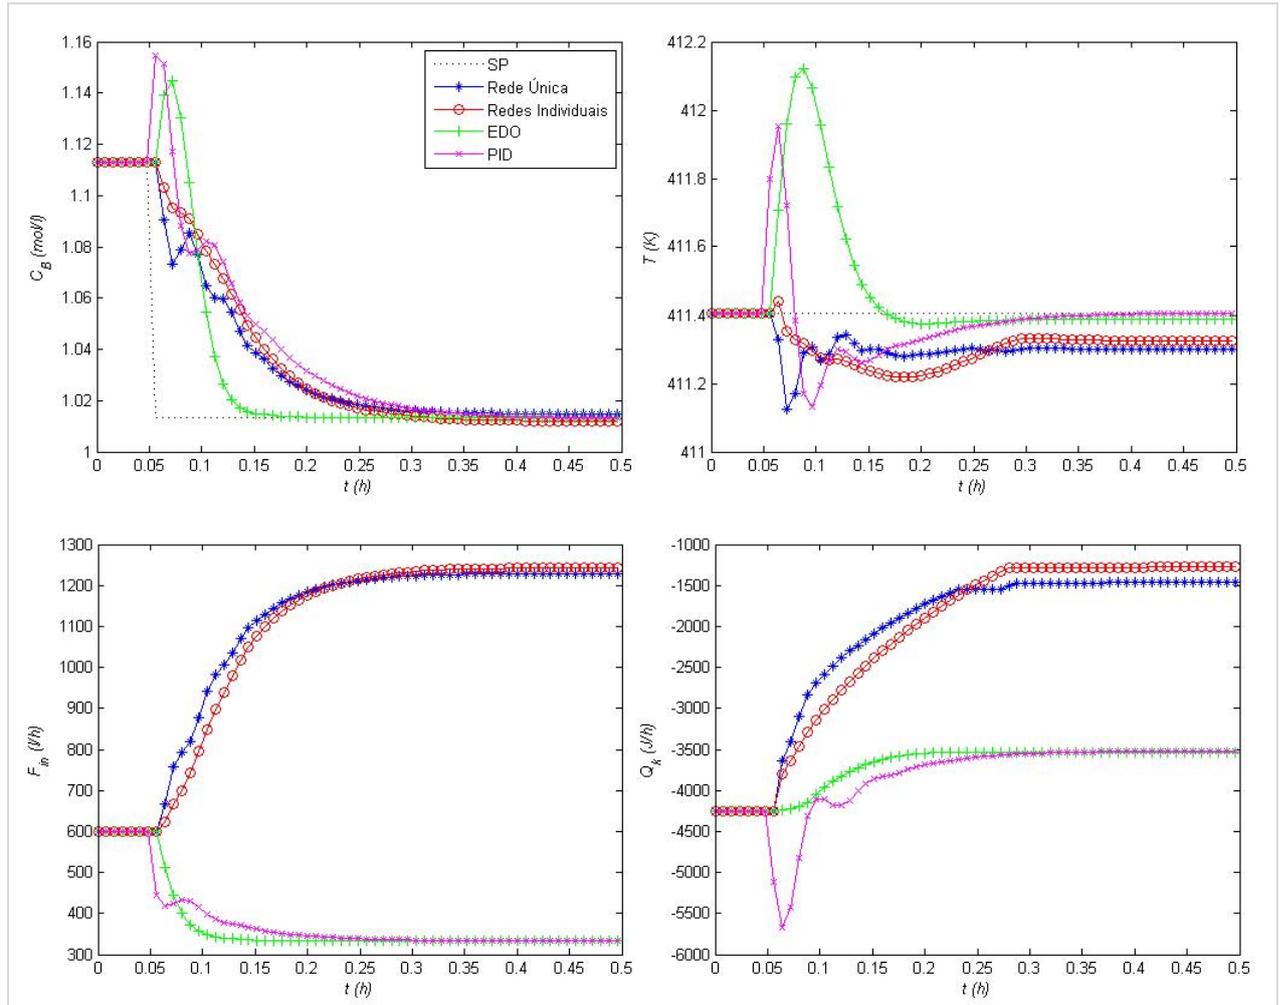


Figura 61 – Redução de SP de C_B .

Tabela 22 – ISE e SU - Redução de SP de C_B .

Controlador	ISE C_B	ISE T	SU F_{in}	SU Q_k
PID	0,090	0,916	$2,58 \times 10^4$	$1,81 \times 10^6$
Redes únicas	0,047	0,759	$2,85 \times 10^4$	$6,92 \times 10^5$
Redes Individuais	0,062	0,759	$2,20 \times 10^4$	$4,68 \times 10^5$
EDO	0,072	2,492	$1,53 \times 10^4$	$4,04 \times 10^4$

Nas simulações do cenário de redução de SP de C_B , conforme já observado anteriormente, tanto os controladores preditivos como o controlador PID, apresentam resultados satisfatórios. Vale observar que os NMPC baseados em redes neurais levaram o processo a região oposta dos controladores PID e NMPC baseado nas EDOs, atingindo o SP por caminhos opostos, o que explica a presença de pequenos *offsets* em relação ao SP desejado de temperatura nos modelos com redes.

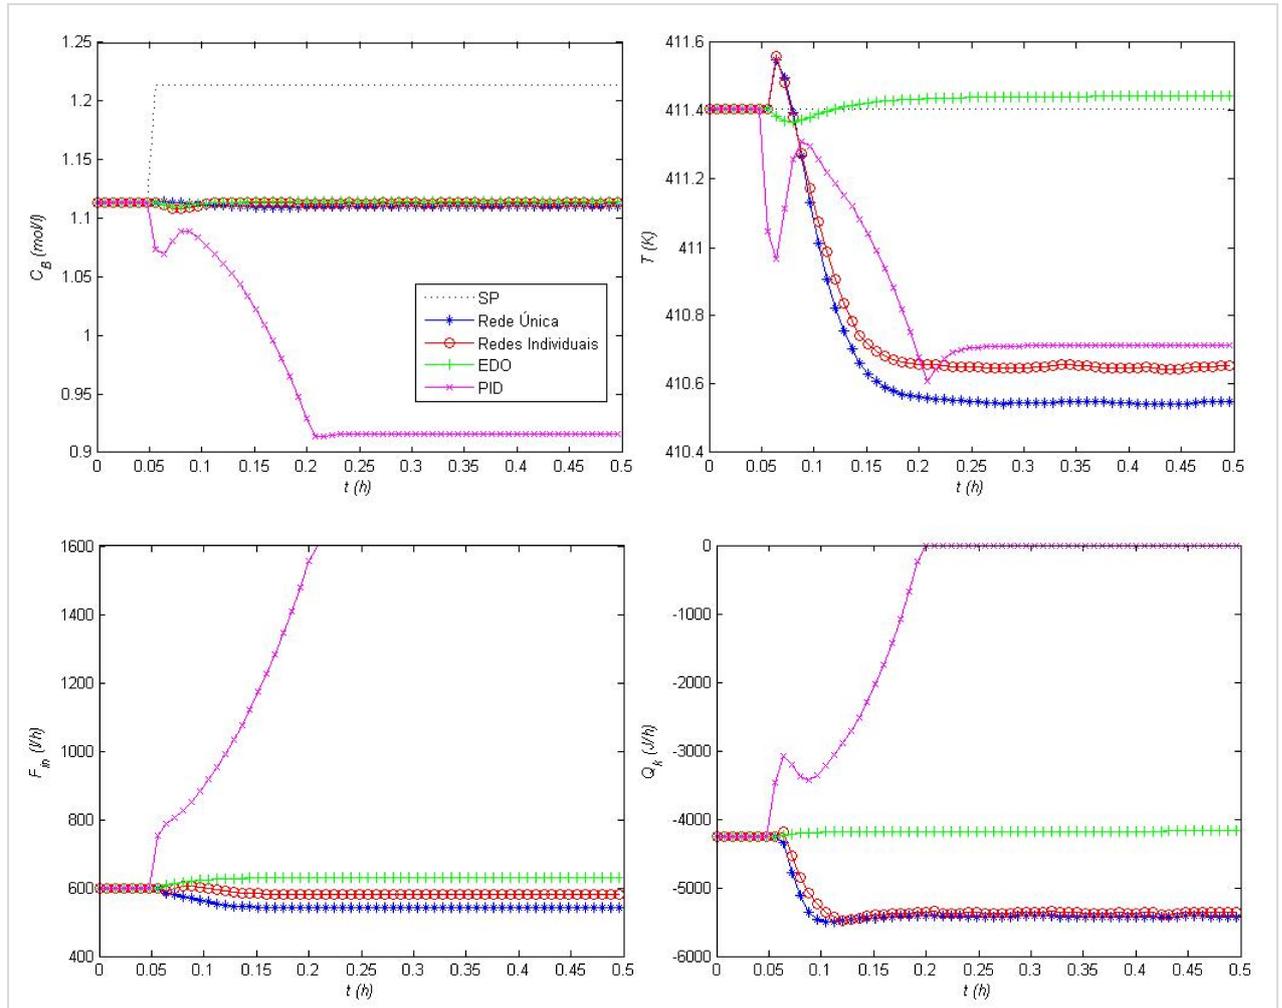


Figura 62 – Aumento de SP de C_B .

Tabela 23 – ISE e SU - Aumento de SP de C_B .

Controlador	ISE C_B	ISE T	SU F_{in}	SU Q_k
PID	3,920	21,13	$6,61 \times 10^4$	$1,80 \times 10^6$
Redes únicas	0,591	34,40	450,40	$3,87 \times 10^5$
Redes Individuais	0,567	26,68	266,13	$2,30 \times 10^5$
EDO	0,552	0,054	127,65	$1,01 \times 10^3$

Conforme já observado anteriormente, o controlador PID não é capaz de manter o processo operando de maneira estável no cenário de aumento de SP de C_B , devido à inversão do ganho do processo. Já os controladores preditivos

mostraram-se eficazes, pois mesmo com um SP inatingível, o processo foi mantido operando de maneira estável em todos os controladores preditivos.

Em relação à temperatura do reator, os NMPC baseados em redes neuronais apresentaram maiores *offsets*, mais acentuado no modelo com redes únicas.

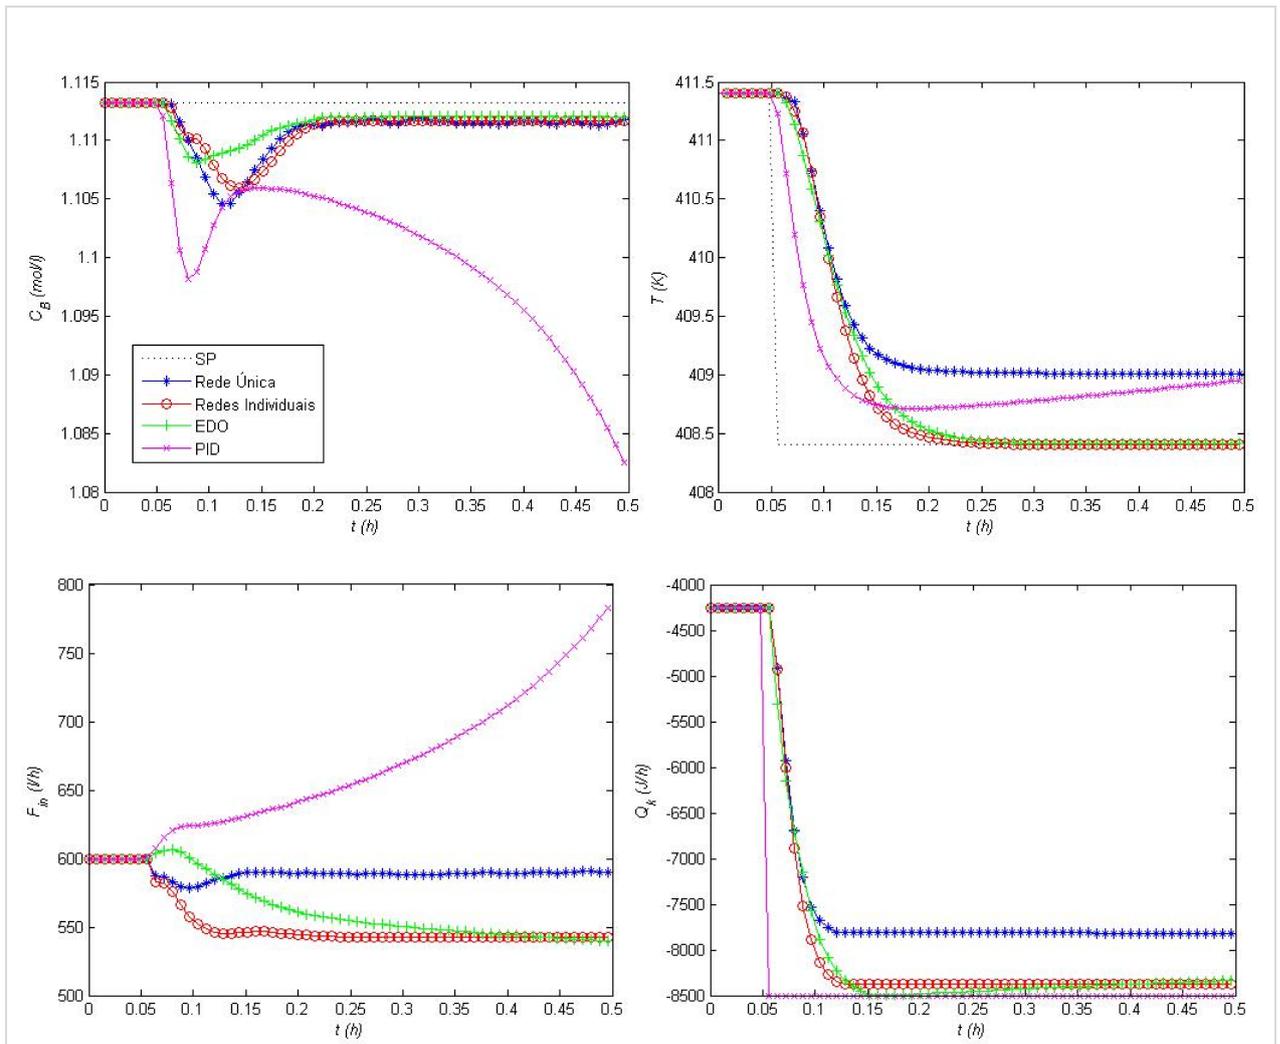


Figura 63 – Redução de SP de T .

Tabela 24 – ISE e SU - Redução de SP de T .

Controlador	ISE C_B	ISE T	SU F_{in}	SU Q_k
PID	0,012	28,84	807,29	$1,81 \times 10^7$
Redes únicas	$5,79 \times 10^{-4}$	63,29	213,57	$2,44 \times 10^6$
Redes Individuais	$4,87 \times 10^{-4}$	48,36	552,56	$3,02 \times 10^6$
EDO	$2,52 \times 10^{-4}$	47,52	183,41	$2,69 \times 10^6$

No cenário de redução do SP de temperatura, o controlador PID instabilizou o processo aumentando constantemente a vazão, já o NMPC baseado em redes únicas estabilizou o processo num condição um pouco afastada do SP desejado para ambas as variáveis.

Os controladores NMPC baseados em redes individuais e EDOs apresentaram bons desempenhos atingindo o estado estacionário desejado de maneira suave.

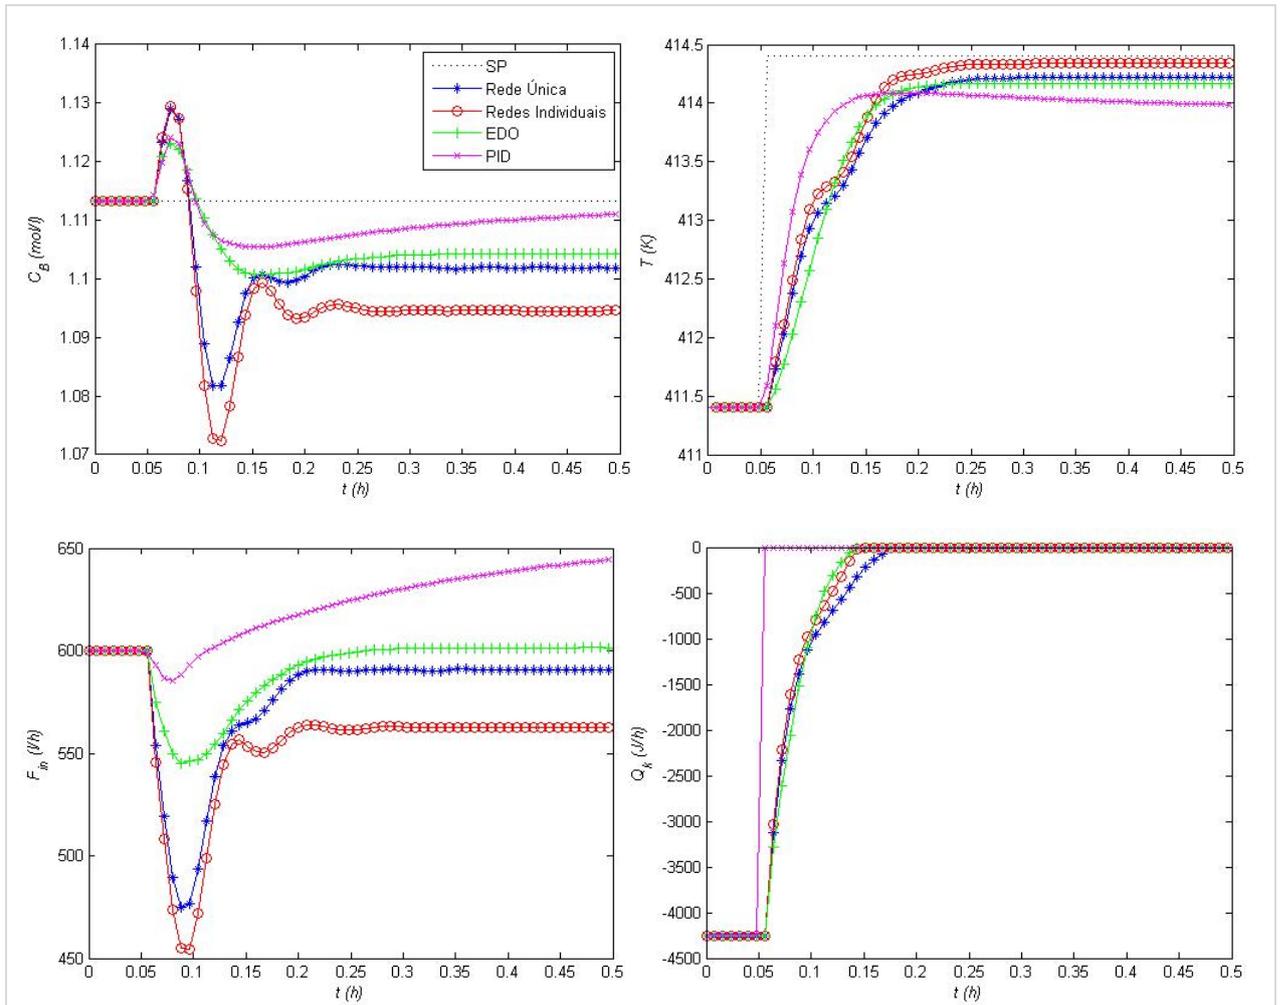


Figura 64 – Aumento de SP de T .

Tabela 25 – ISE e SU - Aumento de SP de T .

Controlador	ISE C_B	ISE T	SU F_{in}	SU Q_k
PID	0,002	27,31	181,42	$1,81 \times 10^7$
Redes únicas	0,010	41,84	$6,12 \times 10^3$	$2,56 \times 10^6$
Redes Individuais	0,022	35,84	$8,14 \times 10^3$	$2,88 \times 10^6$
EDO	0,005	47,60	$1,18 \times 10^3$	$2,42 \times 10^6$

Os controladores NMPC baseados em redes e EDOs levaram o calor retirado ao valor mínimo (zero, sem retirada de calor pela camisa), se aproximando o máximo possível do novo SP de temperatura, e não conseguindo manter o SP de C_B , apresentando um *offset*, mais acentuado para o modelo de redes individuais.

O controlador PID mais uma vez instabilizou o processo, enquanto o NMPC com redes únicas apresentou um offset maior em relação ao SP de temperatura, porém menor em relação a C_B .

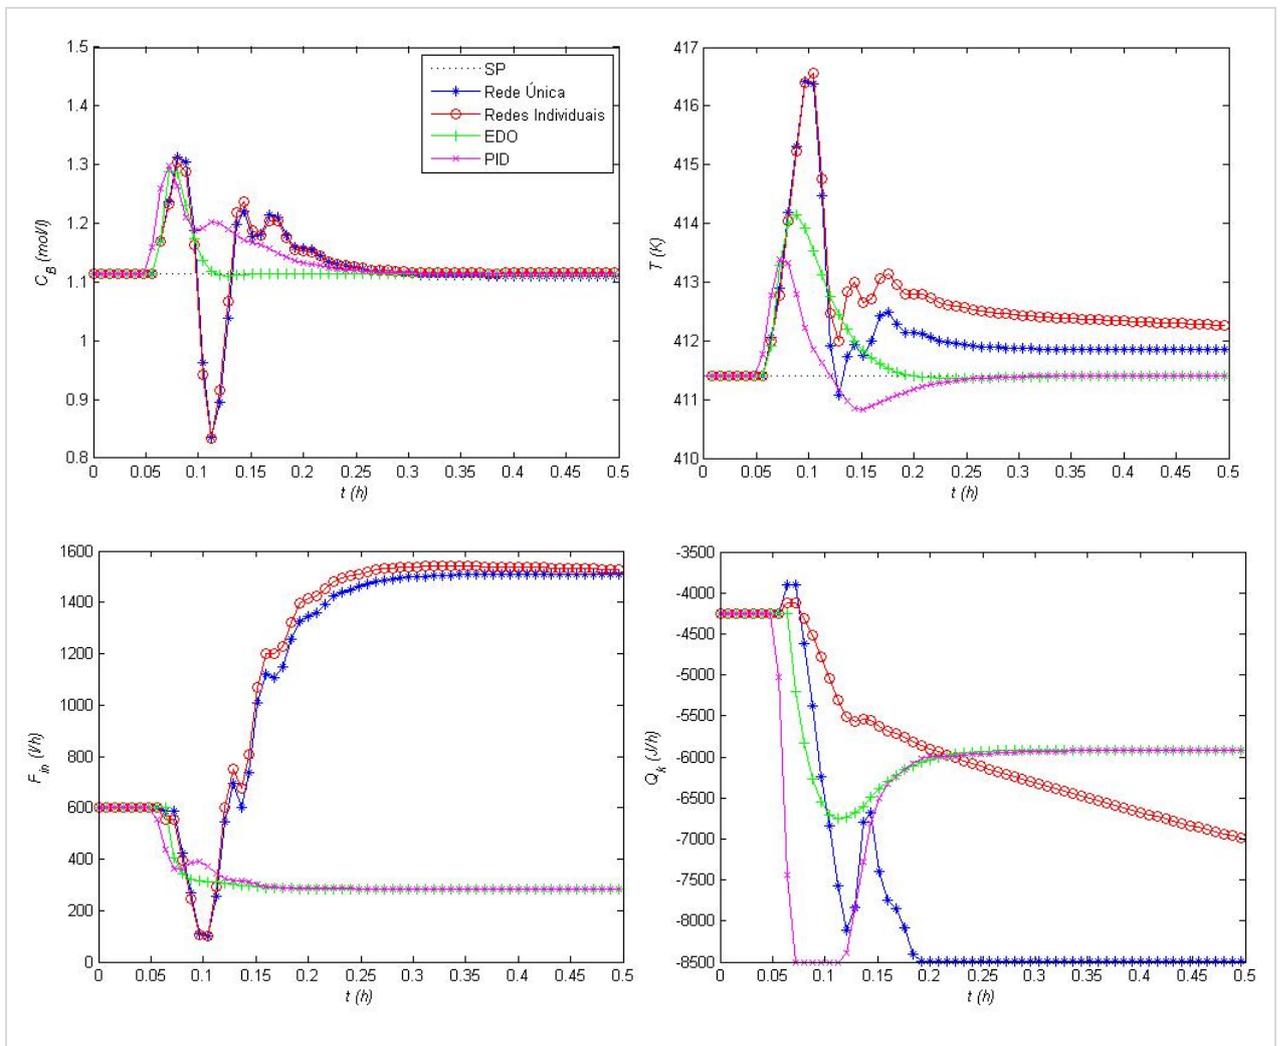


Figura 65 – Perturbação positiva em C_{Ain} .

Tabela 26 – ISE e SU - Perturbação positiva em C_{Ain} .

Controlador	ISE C_B	ISE T	SU F_{in}	SU Q_k
PID	0,142	14,29	$2,37 \times 10^4$	$8,55 \times 10^6$
Redes únicas	0,313	98,50	$3,41 \times 10^4$	$5,12 \times 10^6$
Redes Individuais	0,300	146,04	$3,51 \times 10^4$	$4,02 \times 10^5$
EDO	0,082	36,01	$4,26 \times 10^4$	$1,66 \times 10^6$

No cenário de perturbação positiva na concentração de entrada de A (C_{Ain}), todos os controladores conseguiram manter o SP de concentração de B, inclusive o PID. Porém, o SP da temperatura do reator só foi mantido nos controladores PID e NMPC baseado em EDOs. Ambos os controladores NMPC baseados em redes neurais apresentaram offset em relação à temperatura.

Nessa simulação, assim como no cenário de redução de SP de C_B , os controladores baseados em redes levaram o processo a regiões opostas aos controladores PID e baseados nas EDOs, o que explica o *offset* apresentado na temperatura, já que nessa região mesmo com o calor retirado sendo levado ao valor máximo (8500 kJ/h), não foi suficiente para manutenção da temperatura no SP desejado, SP este não atingível nessa região do processo.

No cenário de perturbação negativa de C_{Ain} , para o valor de 4 mol/l, conforme pode ser observado na Figura 66, o ponto de máxima concentração de B é reduzido para cerca de 0,9 mol/l. Portanto, o SP inicial é inatingível.

Todos os controladores preditivos apresentaram bons desempenhos, conseguindo levar e manter o processo no ponto de máxima concentração de B, conseqüentemente mais perto possível do SP desejado. O controlador PID levou a vazão de entrada ao valor máximo, afastando o processo do SP desejado, mais uma vez devido à inversão de ganho do processo em relação ao controlador.

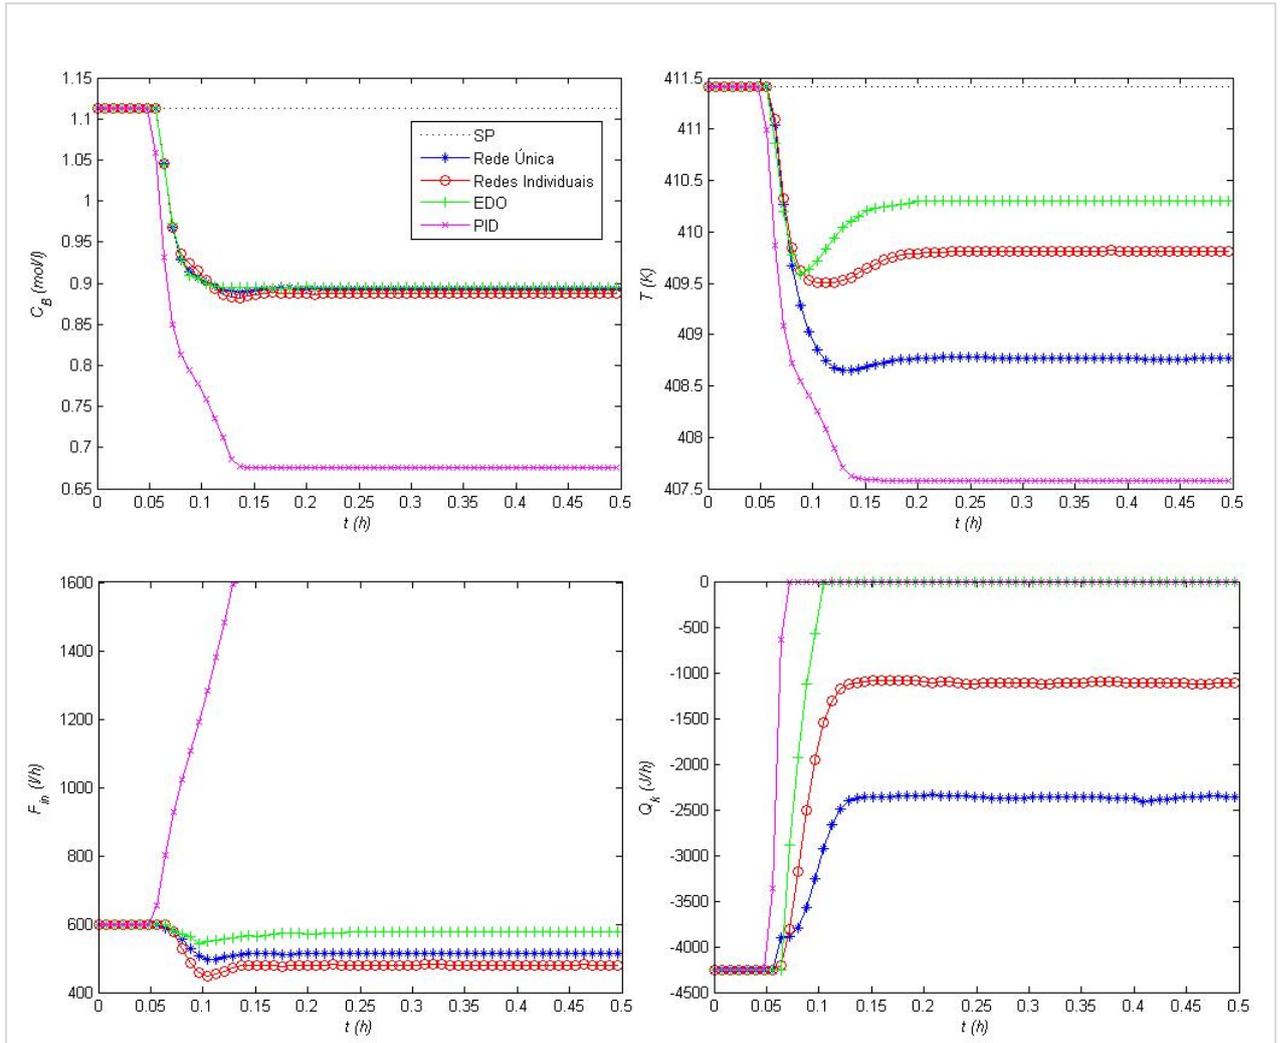


Figura 66 – Perturbação negativa em C_{Ain} .

Tabela 27 – ISE e SU - Perturbação negativa em C_{Ain} .

Controlador	ISE C_B	ISE T	SU F_{in}	SU Q_k
PID	9,82	754,3	$1,05 \times 10^5$	$8,60 \times 10^6$
Redes únicas	2,56	365,73	$2,27 \times 10^3$	$5,00 \times 10^5$
Redes Individuais	2,69	145,49	$5,74 \times 10^3$	$1,56 \times 10^6$
EDO	2,53	78,32	$1,18 \times 10^3$	$4,02 \times 10^6$

Analisando os diversos resultados de cada cenário, nota-se que os controladores PID só funcionam nos cenários quando o novo estado estacionário não ultrapassa a região de inversão de ganho do processo, tais como: Redução de SP de C_B e Perturbação Positiva em C_{Ain} .

Com relação aos controladores preditivos, o modelo com redes únicas apresentou maiores *offset* em relação aos SP desejados, porém é destacável que em nenhum cenário o controlador instabilizou o processo, ao contrário dos controladores PID.

Em geral os controladores baseados em redes individuais e EDOs apresentaram bons desempenhos para os diversos cenários, sendo capazes de manter o processo estável numa região ótima, nos cenários com *setpoints* inatingíveis. Comparando individualmente, os controladores baseados em EDOs apresentaram melhores resultados em relação aos controladores baseados em redes individuais, onde em alguns cenários, foi possível observar pequenos *offset* em relação aos *setpoints* desejados, o que já era esperado já que o modelo baseado em EDO apresenta uma predição perfeita do processo. Porém, é importante observar a diferença entre os tempos de simulações a cada tempo de amostragem. A Tabela 28 apresenta um resumo dos tempos de simulação médios e máximos de cada controlador preditivo.

Tabela 28 – Tempos de simulação.

Controlador NMPC	Tempo médio⁽¹⁾ (s)	Tempo máximo⁽¹⁾ (s)
Redes únicas	4,0	6,7
Redes Individuais	8,5	13,6
EDOs	21,2	114,5

⁽¹⁾ Tempos obtidos em computador com configuração: Processador Intel® Core i7-3537U (2,0GHz até 3.1GHz com Intel® Turbo Boost 2.0); Memória RAM de 8GB; Windows 8.

Como pode ser observado, o NMPC baseado em EDO exige um tempo de simulação a cada instante de amostragem bem elevado, com tempo máximo bem superior ao tempo de amostragem utilizado, 28,8 s (0,008h), o que inviabilizaria a utilização deste controlador. Já os NMPC baseados em rede neuronais apresentam, mesmo o tempo máximo, inferior ao tempo de amostragem. Vale ressaltar que a utilização das redes individuais melhora a capacidade de predição e desempenho do controlador, porém dobra o tempo de simulação em relação as redes únicas.

7 CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

7.1 Conclusões

Os controladores preditivos (lineares ou não lineares) permanecem como importante objeto de estudo de diversos pesquisadores em todo mundo, devido, principalmente, à constante busca por controladores mais estáveis e capazes de controlar processos cada vez mais desafiadores.

O presente trabalho teve como objetivo avaliar o desempenho de um controlador preditivo não linear multivariável baseado em redes neurais. O processo escolhido foi o reator CSTR com cinética de Van de Vusse, considerado como *benchmark* na área de controle, por apresentar – como confirmado no Capítulo 3 – fortes características não lineares como inversão de ganho, multiplicidade de entradas, resposta inversa e comportamento de fase não mínima.

Primeiramente, como referência, o processo foi submetido a controladores PID multimalhas tradicionais. Conforme esperado, os controladores PIDs só foram capazes de operar quando o processo é mantido em uma região restrita, para qual o controlador foi sintonizado. Quando as modificações de *setpoint* ou perturbações levaram o processo à região de inversão de ganho, os controladores instabilizaram o processo.

Na identificação do processo via redes neurais, as redes lineares e MLPs com um dado atrasado não foram capazes de prever devidamente o processo ao longo de um horizonte de predição, apesar de possuírem bons resultados para a predição de um único passo adiante. Já, as redes MLPs com dois dados atrasados apresentaram bons resultados nas predições de longo alcance, apesar de apresentar alguns *offsets*. A utilização de redes individuais, uma rede para cada variável predita, melhorou sensivelmente as predições realizadas, reduzindo os

offsets gerados pelas redes únicas. Três tempos de amostragens foram escolhidos para estudo, 0,002, 0,004 e 0,008h, porém, para a identificação do processo não foi possível notar grandes diferenças entre eles.

Controladores preditivos com predição pelas próprias equações diferenciais do sistema foram modelados para serem comparados aos controladores de redes neurais. Estes controladores, por apresentarem predição perfeita do processo, foram importantes para avaliar quando os problemas eram devidos à qualidade de predição das redes ou inerentes ao próprio controlador não linear.

Os controladores foram submetidos aos três diferentes tempos de amostragem. Notou-se que quanto menor o tempo de amostragem, mais rápido o sistema é levado ao novo estado estacionário, já que mais ações de controle são tomadas em um mesmo intervalo de tempo. Porém, para tempos de amostragem superiores as ações de controle são mais suaves, apresentando menos problemas de instabilidades nos controladores, que foi notada nos tempos de amostragem de 0,002h e 0,004h.

Além dos cenários de alteração de SP de C_B , foram simulados cenários de alteração de SP de T e perturbações na concentração de A da corrente de entrada, utilizando os NMPCs baseados em redes neurais (únicas e individuais) e NMPC baseado nas EDOs. De maneira geral, os NMPC baseados em redes individuais e EDOs apresentam bons resultados para os diversos cenários, inclusive nos cenários com SP inatingíveis. *Offsets* foram observados no NMPC baseado em redes únicas em alguns cenários, porém, o controlador manteve o processo estável em todas situações, ao contrário dos controladores PID que levaram o processo à instabilidade.

Por fim, os tempos de cômputo médios e máximos de cada controlador foram avaliados. O NMPC baseado nas EDOs, mesmo com a introdução da matriz jacobiana analítica, apresentou tempos elevados, em alguns casos superiores ao tempo de amostragem utilizado, o que inviabilizaria a utilização desse controlador. Já os NMPCs baseados em redes neurais apresentaram tempos bem inferiores, o que mostra a viabilidade desses controladores.

7.2 Sugestões para Trabalhos Futuros

As seguintes sugestões podem ser consideradas para trabalhos futuros:

- Avaliação dos controladores com a presença de ruído nas variáveis medidas, podendo também ser utilizadas técnicas adicionais de tratamento de ruídos;
- Redução de dimensão do processo, na tentativa de reduzir os tempos de simulação, e viabilizar a utilização dos controladores baseados em EDOs;
- Utilização de estimadores de estados visando a utilização de variáveis com medições mais fáceis, como pressão, temperatura e densidade, em vez de medições de concentrações, mais difíceis e caras;
- Simulações de novos cenários de perturbações externas como alterações nas constantes de reação, perturbações na temperatura da corrente de alimentação e presença de contaminantes.
- Comparações com técnicas de MPC linear, além de outras técnicas de controle preditivo não linear.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGARWAL, M. A systematic classification of neural-network-based control. **IEEE Control Systems Magazine**, v. 17, p. 75-93, 1997.
- ALLGOWER, F.; BADGWELL, T. A.; QIN, J. S.; RAWLINGS, J. B.; WRIGHT, S. J. Nonlinear predictive control and moving horizon estimation – An introductory overview. **Advances in Control**, p. 391–449, 1999.
- ALLGOWER, F.; FINDEISEN, R.; NAGY, Z. K. Nonlinear model predictive control: from theory to application. **J. Chin. Inst. Chem. Engrs.**, v. 35, n. 3, p. 299-315, 2004.
- ANURADHA, D. B.; REDDY, G. P.; MURTHY, J. S. N. Direct inverse neural network control of a continuous stirred tank reactor (CSTR). **Proceedings of the International MultiConference of Engineers and Computer Scientists**, v. 2, p. 978-988, 2009.
- BANERJEE, P.; SHAH, S.L. The Role of Signal Processing Methods in the Robust Design of Predictive Control. **Automatica**, v. 31, n. 5, p. 681-695, 1995.
- BAUER, M.; CRAIG, I. K. Economic assessment of advanced process control - A survey and framework. **Journal of Process Control**, v. 18, p. 2-18, 2008.
- BEQUETTE, B. W. **Process Control: Modeling, Design and Simulation**. New Jersey: Prentice Hall PTR, 2002.
- BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC Editora, 2000.
- CAMACHO, E. F.; BERENGUEL, M.; RUBIO, F. R. Application of gain scheduling generalized predictive controllers to a solar power plant. **Control Engineering Practice**, v. 2, p. 227-238, 1994.

- CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. London: Springer-Verlag, 2007.
- CAVALCANTI, A. L. O. **Estudo e implementação de um controlador preditivo generalizado bilinear compensado adaptativo**. 2003. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal do Rio Grande do Norte, Natal.
- CHEN, H. **Stability and robustness considerations in nonlinear model predictive control**. Dusseldorf: VDI Verlag, 1997.
- CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. Generalized predictive control – Part I. The basic algorithm. **Automatica**, v. 23, n. 2, p. 137-148, 1987a.
- CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. Generalized predictive control – Part II. Extensions and interpretations. **Automatica**, v. 23, n. 2, p. 149-160, 1987b.
- CLAUMANN, C. A. **Desenvolvimento e aplicações de redes neurais *wavelets* e da teoria de regularização na modelagem de processos**. 2003. Tese (Doutorado em Engenharia Química) - Departamento de Engenharia Química e Engenharia de Alimentos, Universidade Federal de Santa Catarina, Florianópolis.
- COOPER, D. Sample Time is a Fundamental Design and Tuning Specification. 2007. Disponível em < <http://www.controlguru.com/2007/012807.html>>. Acesso em: 10 nov. 2013.
- CUNHA NETO, J. V. **Controle e introdução ao diagnóstico de um reator químico**. 2005. Dissertação (Mestrado em Engenharia Química) – Escola de Química, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- CUTLER, C. R.; RAMAKER, B. L. Dynamic matrix control – A computer control algorithm. **AIChE 86th National Meeting**, Houston, 1979.
- DE NICOLAO, G.; MAGNI, L.; SCATTOLINI, R. **Nonlinear Model Predictive Control**. Birkhauser, 2000.
- DE SOUZA JR., M. B. **Controle Preditivo de Longo Alcance: Uma Investigação**. 1989. Dissertação (Mestrado em Engenharia Química) – COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

- DE SOUZA JR., M. B. **Redes Neurais Multicamadas Aplicadas a Modelagem e Controle de Processos Químicos**. 1993. Tese (Doutorado em Engenharia Química) – COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- DE SOUZA JR., M. B. **Redes Neurais Artificiais na Engenharia Química, Apostila da disciplina de Redes Neurais**, Escola de Química, Universidade Federal do Rio de Janeiro, 2010.
- DE SOUZA, S. J.; SECCHI, A. R. Parametrização automatizada das variáveis de controle em problemas de otimização dinâmica. **VI Oktober Fórum – PPGEQ**, 2007.
- DOS SANTOS, J. E. S. **Controle preditivo não-linear para sistemas de Hammerstein**. 2007. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Santa Catarina, Florianópolis.
- DURAIKI, R. G. **Controle preditivo não linear utilizando linearizações ao longo da trajetória**. 2001. Dissertação (Mestrado em Engenharia Química) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- ENGELL, S.; KLATT, K. U. Nonlinear control of a non-minimum-phase CSTR. **Proceedings of the American Control Conference**, São Francisco, 1993.
- GARCIA, C. E.; MORSHEDI, A. M. Quadratic programming solution of dynamic matrix control (QDMC). **Chem. Eng. Commun.**, v. 46, p. 73-87, 1986.
- GARCIA, C. E.; PRETT, D. M.; MORARI, M. Model predictive control: Theory and practice – a survey. **Automatica**, v. 25, p. 335-348, 1989.
- HAYKIN, S. **Redes Neurais: Princípio e Prática**. Porto Alegre: Bookman, 2001.
- HENSON, M. A. Nonlinear model predictive control: Current status and future definitions. **Computers and Chemical Engineering**, v. 23, p. 187-202, 1998.
- HENSON, M. A.; SEBORG, D. E. **Nonlinear process control**. Prentice Hall, 1997.
- HIMMEBLAU, D. M. Applications of artificial neural networks in chemical engineering. **Korean J. Chem. Eng.**, v. 17, n. 4, p. 373-392, 2000.

- KOTHARE, S. L. O.; MORARI, M. Contractive model predictive control for constrained nonlinear systems. **IEEE Transactions on Automatic Control**, v. 45, n. 6, 2000.
- LI, W. C.; BIEGLER, L. T. Multistep newton-type control strategies for constrained nonlinear processes. **Chemical Engineering Research & Design**, v. 67, p. 562-577, 1989.
- MAMANI, A. B. A. **Utilização de redes neurais no controle da velocidade de um veículo experimental**. 2004. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas.
- MANENTI, F. Considerations on nonlinear model predictive control techniques. **Computers and Chemical Engineering**, v. 35, p. 2491-2509, 2011.
- MAYNE, D. Q.; RAWLINGS, J. B.; RAO, C. V.; SCOKAERT, P. O. M. Constrained model predictive control: Stability and optimality. **Automatica**, v. 36, p. 789-814, 2000.
- MELEIRO, L. A. C. **Projeto e aplicações de controladores baseados em modelos lineares, neurais e nebulosos**. 2002. Tese (Doutorado em Engenharia Química) – Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas.
- MONTANHEIRO, C. E. **Estratégias de identificação e controle aplicadas a um reator químico não linear: Uma introdução à aplicação de ensembles de redes neurais**. 2004. Dissertação (Mestrado em Engenharia Química) – Escola de Química, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- MORARI, M.; LEE, J. H. Model predictive control: past, present and future. **Computers and Chemical Engineering**, v. 23, p. 667-682, 1999.
- MOSCA, E. **Optimal, Predictive and Adaptive Control**. Prentice Hall, 1995.
- NIKRAVESH, M.; FARELL, A. E.; STANFORD, T. G. Dynamic neural network control for non-linear systems: optimal neural network structure and stability analysis. **Chemical Engineering Journal**, v. 68, p. 41-50, 1997.

- NORGAARD, M.; RAVN, O.; POULSEN, N. K.; HANSEN, L. K. **Neural networks for modeling and control of dynamic systems**. Springer-Verlag, 2000.
- NORQUAY, S., PALAZOGLU, A.; ROMAGNOLI, J. A. Application of Wiener model predictive control (WMPC) to a pH neutralization experimente. *IEEE Transactions on Control Systems Technology*, v. 7, p. 437-445, 1999.
- OGUNNAIKE, B. A.; RAY, W. H. **Process Dynamics, Modeling, and Control**. New York: Oxford University Press, 1994.
- OLIVEIRA, N. M. C.; BIEGLER, L. T. An extension of Newton-type algorithms for nonlinear process control. *Automatica*, v. 31, p. 281-286, 1995.
- PETERSON, T.; HERNÁNDEZ, E.; ARKUN, Y.; SCHORK, F. J. A nonlinear DMC algorithm and its applications to a semibatch polymerization reactor. *Chemical Engineering Science*, v. 47, p. 737-753, 1992.
- PROTTES, S. M. **Controlador neural preditivo multivariável aplicado a uma planta piloto de neutralização de pH**. 2009. Dissertação (Mestrado em Engenharia Industrial) – Centro Universitário do Leste de Minas Gerais, Coronel Fabriciano.
- PSICHOGIOS, D. C.; UNGAR, L. H. Direct and indirect model based control using artificial neural networks. *Ind. Eng. Chem. Res.*, v. 30, p. 2564-2573, 1991.
- QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. *Control Engineering Practice*, v. 11, p. 733-764, 2003.
- QIN, S. J.; BADGWELL, T. A. An overview of industrial model predictive control technology. In **J. C. Kantor, C. E. Garcia e B. Carnahan (eds), Chemical Process Control**, v. 93 of AIChE Symposium Series, p. 232-256, 1997.
- QIN, S. J.; BADGWELL, T. A. An overview of nonlinear model predictive control applications. **Proceedings of the IFAC Workshop on Nonlinear model predictive control workshop – Assessment and Future Directions**, Ascona, 1998.
- RICHALET, J.; RAULT, A.; TESTUD, J. L.; PAPON, J. Model predictive heuristic control: Applications to industrial processes. *Automatica*, v. 14, p. 413-428, 1978.

- RODIL, S. S.; FUENTE, M. J. Fault tolerance in the framework of support vector machines based model predictive control. **Engineering Applications of Artificial Intelligence**, v. 23, p. 1127-1139, 2010.
- RUMELHART, D. E.; McCLELLAND, J. L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 1: Foundations**. Cambridge: The Mit Press, 1986.
- SCHNITMAN, L. **Controladores preditivos baseados em redes neurais artificiais**. 1998. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal da Bahia, Salvador.
- SCOKAERT, P. O. M.; MAYNE, D. Q.; RAWLINGS, J. B. Suboptimal model predictive control (feasibility implies stability). **IEEE Transactions on Automatic Control**, v. 44, p.648-654, 1999.
- SEBORG, D. E.; EDGAR, T. F.; MELLICHAMP, D. A. **Process Dynamics and Control**. United States of America: John Wiley & Sons, Inc., 2004.
- SECCHI, A. R.; LONGHI, L. G. S.; TRIERWEILER, J. O. Comparison between linear-adaptive, linear local model network and nonlinear MPC Controllers. **Latin American Applied Research**, v. 31, p. 403-410, 2001.
- TRIERWEILER, J. O. A. **Systematic approach to control structure design**. Dortmund: Shaker Verlag, 1997.
- TRIERWEILER, J. O. A.; SECCHI, A. R. Exploring the potentialy of using multiple model approach in nonlinear model predictive control. **Progress in Systems and Control Theory**, v. 26, p. 191, 2000.
- VOJTESEK, J.; DOSTAL, P. Adaptive Control of Chemical Reactor. **International Conference Cybernetics and Informatics**, 2010.
- VUSSE., J. G. V. Plug Flow Type Reactor versus Tank Reactor. **Chem. Eng. Science**, v. 19, p. 994-997, 1964.
- ZHENG, A.; ZHANG, W. **Nonlinear Predictive Control**. IEE Control Engineering Series, 2001.