



TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA QUÍMICA

MONITORAÇÃO DE DESEMPENHO DE CONTROLADORES PREDITIVOS

Matheus de Souza Escobar
00150303

Orientadores: Prof. Dr. Jorge Otávio Trierweiler
Eng. Rafael Cardoso Dias Costa

Dezembro, 2010

SUMÁRIO

1	INTRODUÇÃO	1
2	REVISÃO BIBLIOGRÁFICA	2
2.1	MPC	2
2.1.1	<i>Estrutura do MPC</i>	3
2.1.2	<i>Tipos de MPC</i>	5
2.1.3	<i>Função Custo e Função Objetivo</i>	8
2.2	AUDITORIA DE DESEMPENHO DE MPC	10
3	DESCRIÇÃO DO SISTEMA	12
4	METODOLOGIA	14
4.1	LINEARIZAÇÃO DO MODELO	15
4.2	PARÂMETROS DO MPC	16
4.3	IMPLEMENTAÇÃO DOS ÍNDICES	18
4.3.1	<i>Variabilidade Relativa (VR)</i>	18
4.3.2	<i>Utilização Efetiva (UE)</i>	21
4.3.3	<i>Desempenho do Modelo (DM)</i>	21
5	DISCUSSÃO E RESULTADOS	21
6	CONCLUSÃO	34
	REFERÊNCIAS	35
	ANEXOS	37

LISTA DE FIGURAS

Figura 1 – Representação esquemática de um MPC.	4
Figura 2 – Ilustração do horizonte de predição e horizonte de controle.	5
Figura 3 – Analogia do MPC.....	5
Figura 4 – Histórico aproximado dos Algoritmos dos MPCs.	6
Figura 5 – Representação esquemática em diagrama de blocos das equações de espaço de estado.8	
Figura 6 – Planta laboratorial de seis tanques.	12
Figura 7 – Validação do modelo linear frente ao não linear para os tanques A) 1 e 2, B) 3 e 4 e C) 5 e 6.....	16
Figura 8 – Desempenho a) servo e b) regulatório do MPC.....	18
Figura 9 – Distribuição das variâncias dos estados do sistema, para a) h_1 , b) h_2 , c) h_3 , d) h_4 , e) h_5 e f) h_6	20
Figura 10 – Diagrama de blocos do processo associado com o MPC.	22
Figura 11 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para <i>set point</i> constante de $h_3 = 13,37\text{ cm}$ e $h_4 = 13,31\text{ cm}$	23
Figura 12 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	24
Figura 13 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	24
Figura 14 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para uma mudança no <i>set point</i> de 3,5 cm em h_3 em $t = 100 \times T_s$ e -3,5 cm para h_4 em $t = 200 \times T_s$	26
Figura 15 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	27
Figura 16 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	27
Figura 17 – Desempenho a) servo e b) regulatório do MPC quando mal sintonizado.	28
Figura 18 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para <i>set point</i> constante de $h_3 = 13,37\text{ cm}$ e $h_4 = 13,31\text{ cm}$, com um controlador mal sintonizado.	30
Figura 19 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	31
Figura 20 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	31
Figura 21 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para um mudança no <i>set point</i> de 3,5 cm em h_3 em $t = 100 \times T_s$ e -3,5 cm para h_4 em $t = 200 \times T_s$, com um controlador mal sintonizado.	32
Figura 22 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	33
Figura 23 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6	33

LISTA DE TABELAS

Tabela 1 – Causas de redução do desempenho de controladores.	1
Tabela 2 – Coeficientes de descarga para os tanques da planta de seis tanques esféricos.....	13
Tabela 3 – Caracterização de Fases do Sistema.	14
Tabela 4 – Restrições das Variáveis Manipuladas, Controladas e Monitoradas.	17
Tabela 5 – Variâncias de referência para as saídas da planta.....	20

LISTA DE ABREVIATURAS E SIGLAS

ARC	Controle Regulatório Avançado
APC	Controle Avançado de Processos
DMC	Controle Baseado em Matrizes Dinâmicas
IDCOM	Identification and Command
LQG	Controlador Gaussiano Quadrático Linear
MPC	Controle Preditivo Multivariável
MPHC	Controle Preditivo Baseado em Modelo Heurístico
MVC	Controlador de Variância Mínima
PID	Controle Proporcional, Integral e Derivativo
SISO	Entrada e Saída Únicas em um Controlador
SMOC	Controlador e Otimizador Multivariável Shell

RESUMO

Controladores Preditivos Multivariáveis, MPCs, são os controladores, na camada supervisória, mais empregados na indústria química atualmente. É importante, logo, a avaliação e monitoração do seu desempenho ao longo do tempo. Valendo-se dessa premissa, o presente trabalho objetiva, através de índices obtidos na literatura, a avaliação do desempenho de um MPC desenvolvido e implementado na UFRGS em um estudo de caso computacional para o controle de uma planta laboratorial de seis tanques esféricos. Tais índices mensuram a relação entre a variabilidade dos estados da planta frente a um *benchmark* estabelecido e a relação entre a variabilidade dos estados preditos pelo MPC e os reais estados da planta. A partir dos resultados obtidos, pôde-se inferir que os índices propostos são de difícil análise, pois os resultados dependem muito dos distúrbios de carga nas variáveis manipuladas. Além disso, caso alguma variável atinja uma restrição, a análise torna-se inconsistente e a aplicação do índice impraticável.

1 Introdução

Dentro da engenharia de processos, estratégias de controle e otimização são ferramentas amplamente utilizadas, com o objetivo de possibilitar uma produção industrial que obedeça a certos indicadores, como flexibilidade operacional, confiabilidade, produtividade, restrições de órgãos ambientais, etc.

De acordo com Ruel (2005), na maioria das plantas industriais mais de 75% dos ativos de uma indústria são ativos de produção e a grande maioria desses ativos então submetidos a algum tipo de controle. Se não estiverem otimizados, os ativos são improdutivos e ineficientes. Do contrário, eles se comportarão conforme foram projetados, ou até melhor. Graças à otimização, a maioria das plantas tem o potencial para aumentar os seus lucros na faixa de algumas centenas de dólares para alguns milhares de dólares.

Em se tratando das estratégias de controle avançado de processos, APC, os controladores preditivos multivariáveis, MPCs, aparecem como os controladores *de facto* mais empregados na indústria química (Patwardhan & McIntyre, 2008). O MPC consiste em uma ferramenta que permite, através de um modelo matemático do sistema controlado, a predição do comportamento deste ao longo do tempo. A grande vantagem consiste na atuação do controlador sobre o sistema antes que ocorra algum prejuízo, seja em termos de produção, seja em termos de segurança, assim como na decisão do melhor caminho para atingir um valor de referência desejado.

Ao longo do tempo, entretanto, o controle do MPC vai gradualmente se degradando. Os problemas típicos de desempenho em uma planta industrial são, genericamente, apresentados como se segue na Tabela 1.

Tabela 1 – Causas de redução do desempenho de controladores.

Problemas Típicos de Malhas de Controle e de Desempenho	Porcentagem (%)
Válvulas de Controle de Baixa Qualidade ou em Estado Ruim	30
Ajuste Pobre de Parâmetros do Controlador	85
Design da Malha de Controle Ruim	15
Controlador no Modo Manual	30
Controlador não operando de acordo com o seu objetivo de controle	85
Malhas com desempenho melhor em modo automático	25

As causas indicadas por Ruel (2005) são pontuais e de suma importância é a sua análise. Patwardhan & McIntyre (2008), entretanto, ainda mencionam que mudanças do processo, sintonia do MPC, falha de instrumentação, problemas de *hardware* e *software*, mudança da matéria-prima, desgaste de equipamentos, manutenções e despreparo de pessoal são fatores que contribuem para a redução do desempenho dos MPCs ao longo do tempo. Logo, é imperativo, além de garantir o desempenho da planta, avaliar o desempenho dos controladores ao longo do tempo.

Mas, como exercer uma monitoração eficiente? Dentre uma série de técnicas de monitoração, o trabalho aqui apresentado tem por objetivo a aplicação de índices encontrados na literatura (Patwardhan & McIntyre, 2008), visando à monitoração de desempenho de um MPC. Ainda, objetiva avaliar se tais índices são capazes de auditar uma malha de controle quando empregado um controlador multivariável. Para tanto, valer-se-á de um estudo de caso computacional, que consiste na simulação do controle de uma planta de seis tanques esféricos.

O trabalho apresenta a seguinte estrutura: inicialmente, uma revisão bibliográfica sobre MPCs e monitoração de desempenho é apresentada no primeiro capítulo. Posteriormente, o sistema estudado é descrito, seguido pela metodologia de implementação do MPC e dos índices, caracterizando o segundo e terceiro capítulos, respectivamente. Logo após, é feita a discussão dos resultados obtidos no estudo e, por fim, apresentadas as conclusões e propostas para trabalhos futuros.

2 Revisão Bibliográfica

2.1 MPC

Entende-se por controle avançado de processos toda a estratégia de controle cuja complexidade é dita maior que a de um controle proporcional, integral e derivativo, PID, simples. Diversas técnicas e estratégias podem ser usadas, algumas se tratando simplesmente de controle regulatório avançado, ARC, e outras se voltando para controle avançado de processo, APC.

MPCs tiveram suas origens firmadas há aproximadamente cinco décadas, quando Zadeh e Whalen (1962) realizaram uma conexão entre o problema ótimo de

tempo mínimo e a programação linear, e Propoi (1963) sugeriu pela primeira vez que uma aproximação por horizonte móvel poderia ser utilizado para este problema de controle. Tais estratégias se referem a uma classe de algoritmos computacionais que, utilizando um modelo explícito do processo, prediz as respostas futuras da planta.

O MPC desponta nesse cenário como uma ferramenta altamente empregada. De acordo com Tatjewski (2007), há três razões principais para se utilizar MPCs. Primeiro, eles levam em consideração restrições nas entradas e saídas do sistema, garantindo qualidade, eficiência e segurança na produção. Segundo, com a utilização de um modelo do processo, é possível gerar saídas do controlador que levem em consideração interações internas do sistema, podendo operar com processos de difícil dinâmica e cujo número de variáveis manipuladas e controladas não seja igual. Terceiro, salientando uma vantagem do ponto de vista prático da utilização de MPCs, o princípio de operação dos algoritmos é compreensível e razoavelmente fácil de explicar a um grupo de trabalho de uma instalação industrial, o que é um ponto chave ao introduzir novas técnicas nesse tipo de ambiente.

Levando em consideração tais vantagens, o MPC pode ser facilmente empregado em sistemas multivariáveis, trabalhando com limitações no atuador e nas variáveis controladas e manipuladas, através de restrições explícitas. Ainda, permite a utilização de *targets*, ou seja, valores desejáveis para as variáveis manipuladas, assim como controle de variáveis tanto por *set point*, como por faixas de operação (Camacho e Bordons, 1999). É um controlador que apresenta versatilidade, eficiência e cujas vantagens corroboram a sua tão ampla utilização na indústria.

2.1.1 Estrutura do MPC

Um MPC apresenta genericamente uma estrutura básica como é mostrado na Figura 1, consistindo basicamente de um modelo, que representa uma abstração matemática do processo que se deseja controlar, e um algoritmo de otimização, cujo objetivo é determinar a ação de controle a ser aplicada no sistema para cada instante de tempo.

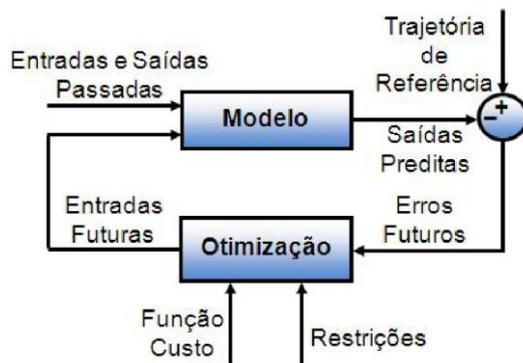


Figura 1 – Representação esquemática de um MPC.

A metodologia, ou estratégia, utilizada pelo MPC é bem característica. Conforme descrito por Camacho e Bordons (1999), a cada intervalo de tempo, o modelo calcula, a partir das entradas e saídas do processo e das entradas futuras do processo determinadas no instante anterior, as saídas futuras do sistema para um horizonte de predição P . Posteriormente, o algoritmo de otimização obtém como resultado uma sequência de ações através de minimização do erro entre os valores preditos pelo modelo para as saídas e os valores de referência dos *set points*. O MPC utiliza o estado atual como condição inicial para a predição do modelo, e a otimização fornece a melhor sequência de ações dentro de um horizonte de controle pré-determinado M , em que somente a primeira ação de controle desta sequência é aplicada à planta. A figura 2 ilustra os conceitos de horizonte de predição e horizonte de controle.

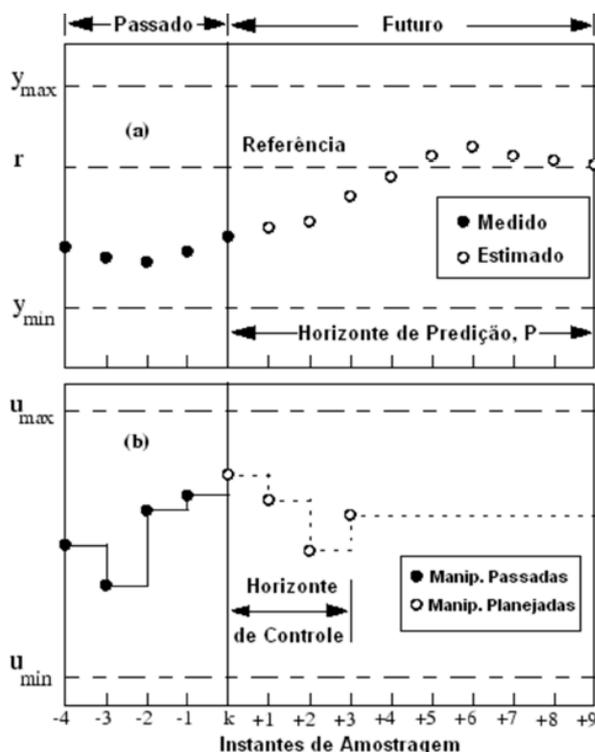


Figura 2 – Ilustração do horizonte de predição e horizonte de controle.

Valendo-se de uma analogia, o controle de um MPC é muito similar ao controle de um carro. A Figura 3 ilustra bem a situação. Ao dirigir, o motorista sabe a trajetória desejada para um horizonte finito P . Ao levar em consideração as características do carro, uma espécie de modelagem mental do carro, ele decide qual ação tomar, acelerar, frear, girar o volante, etc. Somente a primeira ação de controle é tomada a cada instante e o procedimento é repetido para as próximas ações de controle ao longo do tempo. Fazendo uma comparação com métodos mais tradicionais, como PID, que levam em consideração os erros passados, através da ação integral, o erro presente, através da ação proporcional, e a tendência de erro futuro com a ação derivativa, poderíamos dizer que neste caso seria como dirigir o carro à noite com o farol baixo, enquanto que o controlador preditivo seria como dirigi-lo com os faróis altos. (Martin-Sanchez & Rodellar, 1996).

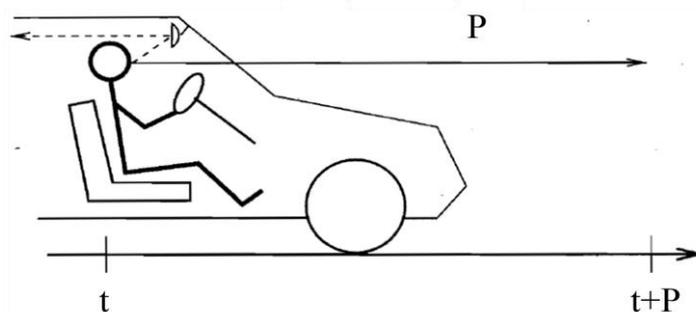


Figura 3 – Analogia do MPC.

2.1.2 Tipos de MPC

A tecnologia MPC apresenta uma série de vertentes. A Figura 4 mostra uma árvore evolucionária, apresentando os MPCs industriais mais relevantes, ilustrando a sua conexão de uma maneira concisa.

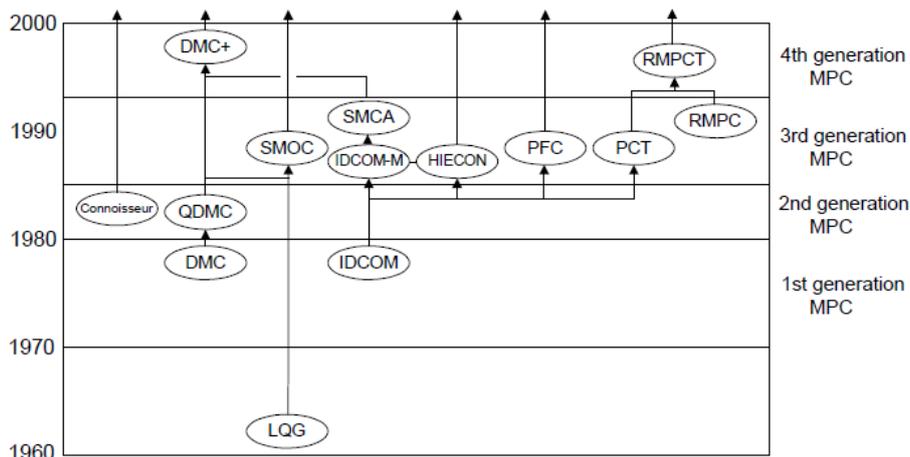


Figura 4 – Histórico aproximado dos Algoritmos dos MPCs.

Em meados de 1970, a primeira descrição de uma aplicação industrial foi apresentada por Richalet *et al.* (1976), descrevendo o que seria o MPHC, Controle Preditivo Baseado em Modelo Heurístico. A relação entre as entradas e saídas do sistema dá-se de modo direto, a partir de um função resposta impulso finita. Para o caso SISO, uma entrada e uma saída, o modelo é descrito conforme a equação 1.

$$y_{k+j} = \sum_{i=1}^P h_i u_{k+j-i} \quad (1)$$

Onde os coeficientes h_i representam os coeficientes da resposta impulso. As saídas do modelo são, logo, uma combinação linear dos valores de entrada passados, que são truncados até certo instante onde esses valores não têm mais influência nas saídas futuras. O MPHC foi empregado no software IDCOM, *Identification and Command*, sendo este o precursor de uma gama de outros controladores que viriam a ser elaborados.

Uma segunda linha de MPCs foi desenvolvida na mesma época por engenheiros da empresa *Shell Oil*, Cutler & Ramaker (1979), chamado de DMC, Controle Baseado em Matrizes Dinâmicas. Diferentemente do MPHC, o DMC trabalha com modelos de resposta degrau lineares, com a seguinte forma, de acordo com a equação 2.

$$y_{k+j} = \sum_{i=1}^{P-1} (s_i \Delta u_{k+j-i} + s_P u_{k+j-P}) \quad (2)$$

Onde s_i são os coeficientes de resposta degrau para o horizonte de predição P . Valendo-se do princípio de superposição, possível graças a essa representação, pode-se trabalhar com múltiplas saídas. Utilizando a resposta degrau, o modelo pode prever as mudanças nas saídas do processo como uma combinação linear das entradas futuras no processo. A matriz que relaciona esses dois conjuntos de valores é a chamada matriz dinâmica, composta pelos coeficientes de resposta

degrau das variáveis dentro do horizonte de predição P . Essa tecnologia, em conjunto com o MPHC, caracteriza a primeira geração de MPC desenvolvida.

Os primeiros trabalhos referentes a espaços de estado, entretanto, foram apresentados por Kalman (1960a, 1960b), onde sistemas no domínio discreto foram representados como modelos em espaço de estado, e, a partir dessa representação, o controlador LQG, Controlador Gaussiano Quadrático Linear, foi elaborado. Tal momento representa o advento da teoria que levaria à elaboração do SMOC, Controlador e Otimizador Multivariável Shell, no final da década de 80, considerado como uma ponte entre a tecnologia de espaço de estados e os algoritmos do MPC (Marquis & Broustail, 1998; Yousfi & Tournier, 1991). Para o trabalho em questão, o MPC foi desenvolvido a partir de representação em espaço de estados, sendo o foco desse trabalho. É importante salientar a importância e aplicabilidade dessa tecnologia, visto a maioria das aplicações industriais de MPCs existentes hoje em dia trabalham com esse tipo de modelo.

A representação de um sistema linearizado, no domínio discreto e em espaço de estados é mostrada nas equação 3 e 4 (Maciejowski, 2000).

$$\Delta x_{k+1} = A\Delta x_k + B_u\Delta u_k + B_d\Delta d_k \quad (3)$$

$$y_{k+1} = C\Delta x_{k+1} + D\Delta u_{k+1} + y_k \quad (4)$$

$$A = \begin{bmatrix} \left. \frac{\partial f_1}{\partial x_1} \right|_{x_{ss}} & \dots & \left. \frac{\partial f_1}{\partial x_n} \right|_{x_{ss}} \\ \vdots & \ddots & \vdots \\ \left. \frac{\partial f_n}{\partial x_1} \right|_{x_{ss}} & \dots & \left. \frac{\partial f_n}{\partial x_n} \right|_{x_{ss}} \end{bmatrix} \quad B_u = \begin{bmatrix} \left. \frac{\partial f_1}{\partial u_1} \right|_{u_{ss}} & \dots & \left. \frac{\partial f_1}{\partial u_m} \right|_{u_{ss}} \\ \vdots & \ddots & \vdots \\ \left. \frac{\partial f_n}{\partial u_1} \right|_{u_{ss}} & \dots & \left. \frac{\partial f_n}{\partial u_m} \right|_{u_{ss}} \end{bmatrix} \quad B_d = \begin{bmatrix} \left. \frac{\partial f_1}{\partial d_1} \right|_{d_{ss}} & \dots & \left. \frac{\partial f_1}{\partial d_r} \right|_{d_{ss}} \\ \vdots & \ddots & \vdots \\ \left. \frac{\partial f_n}{\partial d_1} \right|_{d_{ss}} & \dots & \left. \frac{\partial f_n}{\partial d_r} \right|_{d_{ss}} \end{bmatrix}$$

$$x = (x_1, x_2, \dots, x_n), \quad u = (u_1, u_2, \dots, u_m) \text{ e } d = (d_1, d_2, \dots, d_l)$$

Onde x corresponde aos estados do sistema, y às variáveis de saída do sistema, u às ações de controle e d aos distúrbios medidos. A é uma matriz quadrada que indica a relação entre as variáveis de estado atuais com as variáveis de estado futuras. B_u e B_d são matrizes que indicam o impacto de cada variável de entrada do processo e distúrbios medidos no sistema nos estados futuros. C é uma matriz cujo objetivo é estabelecer uma saída y como uma combinação linear dos estados existentes. A matriz D , por fim, indica a existência de variáveis de entrada cujo efeito é imediato na saída do processo, caracterizando o chamado *feed-through*. É importante salientar, ainda, que essas matrizes apresentadas são dependentes somente do ponto onde a linearização do modelo foi realizada, sendo, para todos os efeitos, constantes.

A representação em diagrama de blocos dessas equações pode ser vista na Figura 5

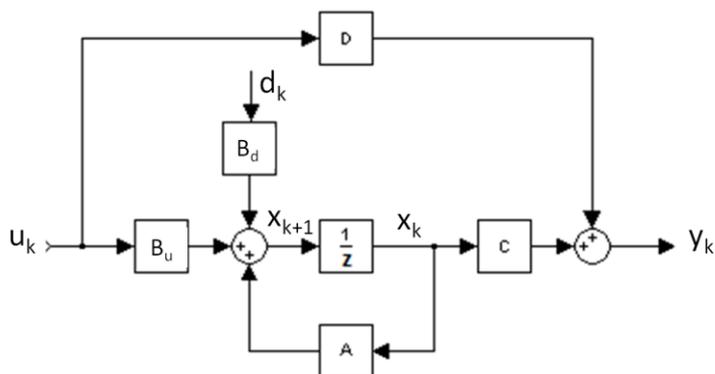


Figura 5 – Representação esquemática em diagrama de blocos das equações de espaço de estado.

A partir desse modelo, determinam-se as saídas previstas do sistema para o horizonte de predição P . Devido, entretanto, à formulação do algoritmo de otimização, as saídas são representadas de maneira distinta da apresentada anteriormente, como pode ser visto na equação 5.

$$Y_{[k+1]}^{[k+P]} = Su \cdot \Delta U_{[k+1]}^{[k+M]} + Sx \cdot \Delta x_{[k+1]}^{[k+P]} + Sd \cdot \Delta d_{[k+1]}^{[k+M]} + I_{((P.ny) \times ny)} \cdot y_k + W_k \quad (5)$$

Onde as matrizes Su , Sx e Sd são combinações lineares das matrizes A , B e C (Anexo 1), W_k é a diferença entre o valor medido y_k com o valor predito \hat{y}_k , estabelecendo assim uma maneira de se levar em consideração os distúrbios não medidos e Y representa as saídas do modelo previstas desde o instante $k + 1$ até o instante $k + P$.

2.1.3 Função Custo e Função Objetivo

Devido à possibilidade de trabalhar com restrições tanto nas variáveis controladas como nas manipuladas, MPCs permitem estratégias de controle distintas. Partindo dessa premissa, o conceito de *targets*, *soft constraints* e *hard constraints* é fundamental (Huang & Kadali, 2009).

Em se tratando de limitações físicas de equipamento, como limites de temperatura, altura máxima de líquido em um tanque, abertura de válvulas, entre outros, diz-se que tais restrições representam *hard constraints*, ou seja, restrições que não podem, sob hipótese alguma, serem transgredidas. Seja porque não há significado físico, como 110% de abertura de uma válvula, seja porque há risco de dano ao equipamento, no caso de temperatura muito alta de um forno, por exemplo.

As *soft constraints* são utilizadas ao se empregar controle por faixas. Estabelecendo uma faixa de operação para uma variável, dita como monitorada, as *soft constraints* aparecem justamente como os limites da faixa. Estas restrições não são absolutas, ou seja, podem ser transgredidas. Enquanto a variável estiver fora da faixa, entretanto, caberá ao controlador trazê-la de volta a valores aceitáveis.

Finalmente, dependendo das variáveis manipuladas disponíveis para controle, é interessante manter algumas delas em determinados patamares, usualmente por questões econômicas. Partindo desse pressuposto, o conceito de *target* pode ser aplicado. Analogamente às variáveis controladas, o *target* pode ser interpretado como o *set point* das manipuladas. Usando dessa ferramenta, pode-se impedir que uma variável com um valor agregado alto seja usada indiscriminadamente.

Em termos da otimização, simplesmente um peso maior é associado a essa variável, condicionando a sua utilização ao peso estabelecido. A função custo existente em um algoritmo de otimização de um MPC é apresentada, na sua forma mais completa, para uma representação em espaço de estados, conforme a equação 6. (Maciejowski, 2000).

$$J = \left\| \Gamma_{[k+1]} \cdot \left(Y_{[k+1]} - R_{[k+1]} \right) \right\|_2^2 + \left\| \Lambda_{[k+1]} \cdot \Delta U_{[k+1]} \right\|_2^2 + \left\| \Psi_{[k+1]} \cdot \left(U_{[k+1]} - Z_{[k+1]} \right) \right\|_2^2 + \left\| \Phi \cdot s \right\|_2^2 \quad (6)$$

Onde a função objetivo é expressa na equação 7:

$$F.O. = \min_{\Delta U_{[k+1]}, s} (J) \quad (7)$$

Submetida às restrições descritas pelas equações 8, 9 e 10:

$$U_{MIN} \leq U \leq U_{MAX} \quad (8)$$

$$Y_{MIN} \leq Y \leq Y_{MAX} \quad (9)$$

$$\Delta U_{MIN} \leq \Delta U \leq \Delta U_{MAX} \quad (10)$$

Onde $Y_{[k+1]}$ é descrito pela equação 5. Dessa forma a função objetivo fica somente em função das variáveis de entrada do processo U e da folga s das *soft constraints*, que são as variáveis desejadas na otimização.

Os parâmetros Γ , Λ , Ψ e Φ são pesos dados a cada uma das parcelas da função objetivo. O primeiro termo é correspondente ao erro entre as saídas previstas do controlador, Y , e o valor de referência, R . O segundo termo representa um peso dado à variação de U , visto que, visando à estabilidade do sistema, as variáveis

manipuladas não podem atingir valores demasiadamente distintos em um curto espaço de tempo. O terceiro termo avalia o erro entre as variáveis manipuladas U e seus respectivos targets Z . Por fim, o último termo é referente às *soft constraints* do sistema, onde há uma folga s , que estabelece uma tolerância para a variação fora da faixa das variáveis monitoradas.

O sistema ainda está submetido às *hard constraints*, que estabelecem valores máximos e mínimos para U e Y , além de limites quanto às variações de U .

2.2 Auditoria de Desempenho de MPC

Assim como o PID é o controlador SISO mais utilizado e seu desempenho necessita de uma atenção especial, o MPC é o controlador multivariável com maior aplicação, cujas técnicas de auditoria de desempenho estão em grande demanda. Em virtude de o MPC manejar restrições e otimizações econômicas do processo, a monitoração necessita de um tratamento especial.

Dentre as técnicas existentes de monitoração de desempenho, há dois grandes grupos (Huang e Kadali, 2009). Inicialmente, há a abordagem baseada em modelos, onde o conceito de *benchmarking* é recorrente. *Benchmark* é um padrão de referência para uma determinada propriedade ou variável que, quando comparada com um valor real, permite a avaliação do desempenho do controlador. Usualmente esses métodos utilizam esse artifício para monitorar o desempenho do sistema, valendo-se da equação 11.

$$\eta = \frac{J_{DES}}{J_{REAL}} \quad (11)$$

Onde J_{DES} é o valor de referência do índice de desempenho, e J_{REAL} é o valor “real” da variável, ou seja, o valor obtido através de medições.

Dentre os padrões de desempenho (*benchmark*) mais conhecidos estão o MVC (Harris *et al.* 1996), *minimum variance controller*, LQG (Huang & Shah, 1999), *linear quadratic gaussian*, curva de *tradeoff* do MPC (Patwardhan *et al.*, 2002), *benchmarking* de dados históricos da planta (Zhang & Henson, 1999), validação do modelo *on-line* (Kesavan & Lee, 1997) e a abordagem de simulação baseada em modelo (Ko & Edgar, 2001). A desvantagem desses métodos é a necessidade de

valores de referência e conhecimento de modelos de processo, ou seja, um conhecimento *a priori* profundo do sistema que se deseja analisar.

O segundo grupo vale-se de abordagens independente de modelos, que não utiliza, pois, um *benchmarking* e que, além disso, é geralmente não paramétrico. Em virtude desses fatores são, a princípio, mais atraentes para aplicações industriais. Quando comparados com o primeiro grupo, contudo, apresentam uma maior imprecisão na monitoração, visto que o conhecimento do sistema, a partir de um modelo, provê informações valiosas que possibilitam uma visão mais clara do processo como um todo e das interações entre as variáveis do processo. Para o presente trabalho, a auditoria de desempenho será realizada a partir da primeira abordagem, já que existe uma modelagem clara e um conhecimento amplo sobre o sistema estudado.

Os índices estudados nesse trabalho são originários do trabalho de Patwardhan & McIntyre (2008), como mostrado nas equações 12, 13 e 14.

$$VR = \frac{\sigma_{REF}^2}{\sigma_{REAL}^2} \times 100 \quad (12)$$

$$UE = \frac{t[Controlador \cap ON \cap MV \cap ON \cap MV_{MIN} < MV < MV_{MAX}]}{t_{TOTAL}} \quad (13)$$

$$DM = \frac{\sigma_{PRED}^2}{\sigma_{REAL}^2} \times 100 \quad (14)$$

O primeiro índice, *VR*, refere-se à análise da variabilidade relativa do sistema, avaliando, para tanto, a variabilidade de um valor de referência com a variabilidade real atingida pelo sistema. Parte-se do pressuposto que o objetivo de um controlador é manter a variável controlada ao redor de um *set point* com um mínimo de variabilidade, logo é um índice cujo objetivo é avaliar diretamente o desempenho do controlador como um todo. Em se tratando do valor referência para a variabilidade, há uma série de *benchmarks* que pode ser utilizada. Usualmente, na indústria, dois caminhos são comuns (Huang e Kadali, 2009): dados históricos de planta, obtendo uma referência de um período, ou a variabilidade no momento do projeto do MPC.

O segundo índice avalia a utilização efetiva do controlador ao longo da campanha na planta industrial. Ele é calculado através da razão entre o tempo que o controlador está ativo, suas variáveis manipuladas ativas e, ainda, dentro dos limites. No caso de haver um controlador cuja utilização efetiva seja baixa, tal controlador é, pois, passível de análise.

O terceiro índice avalia diretamente a variabilidade da predição realizada pelo modelo e a variabilidade real obtida. É, pois, um índice que não avalia o controlador como um todo, se focando no desempenho do modelo.

3 Descrição do Sistema

O sistema levado em consideração para os estudos deste trabalho é mostrado na figura 6, estando instalado no Laboratório de Controle e Integração de Processos da Universidade Federal do Rio Grande do Sul (LACIP II – UFRGS).

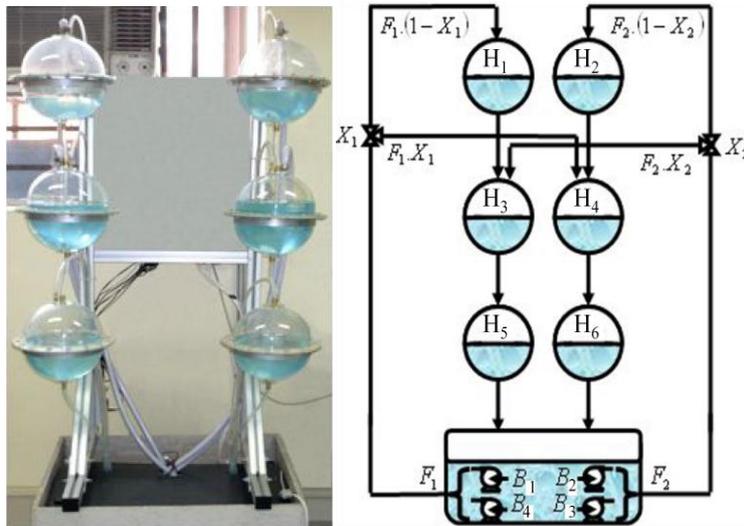


Figura 6 – Planta laboratorial de seis tanques.

O sistema é formado por seis tanques de geometria aproximadamente esférica, os quais estão interligados entre si por tubulações e dispostos em dois ramos de três tanques. Abaixo destes tanques, encontram-se quatro pequenas bombas submersas em um reservatório de água. Através de um único ramal, as bombas B_1 e B_4 operam em paralelo, alimentando os tanques 1 e 4 e, analogamente, o mesmo ocorre para as bombas B_2 e B_3 em relação aos tanques 2 e 3. Os tanques inferiores 5 e 6 recebem a vazão de saída dos tanques intermediários e suas saídas retornam ao reservatório de origem. As vazões das quatro bombas são modificadas através da variação da tensão de alimentação das mesmas e os níveis dos seis tanques são medidos através de células de carga, que também servem de sustentação para os tanques.

Trata-se, portanto, de um processo envolvendo níveis de líquidos. Uma característica interessante desta planta está justamente na escolha pela geometria esférica dos tanques, a qual permite diferentes comportamentos dinâmicos de

acordo com a região de operação do processo. Isto é, ocorre uma variação de nível mais brusca nas regiões próximas ao topo e fundo dos tanques e uma variação mais amena quando se opera na região intermediária dessas esferas.

As equações que representam o sistema são descritas pelas equações 15 a 20.

$$\frac{dh_1}{dt} = \frac{F_1(1-X_1) - CD_1\sqrt{h_1}}{\pi h_1(D-h_1)} \quad (15)$$

$$\frac{dh_2}{dt} = \frac{F_2(1-X_2) - CD_2\sqrt{h_2}}{\pi h_2(D-h_2)} \quad (16)$$

$$\frac{dh_3}{dt} = \frac{CD_1\sqrt{h_1} + F_2X_2 - CD_3\sqrt{h_3}}{\pi h_3(D-h_3)} \quad (17)$$

$$\frac{dh_4}{dt} = \frac{CD_2\sqrt{h_2} + F_1X_1 - CD_4\sqrt{h_4}}{\pi h_4(D-h_4)} \quad (18)$$

$$\frac{dh_5}{dt} = \frac{CD_3\sqrt{h_3} - CD_5\sqrt{h_5}}{\pi h_5(D-h_5)} \quad (19)$$

$$\frac{dh_6}{dt} = \frac{CD_4\sqrt{h_4} - CD_6\sqrt{h_6}}{\pi h_6(D-h_6)} \quad (20)$$

Onde o diâmetro D dos tanques foi aproximado como um valor constante para todos de 22,5 cm. Os coeficientes de descarga foram determinados a partir de curvas de calibração $F_{SS} \times \sqrt{h_{SS}}$ para os seis tanques (Paim, 2009). Os resultados podem ser vistos na Tabela 2.

Tabela 2 – Coeficientes de descarga para os tanques da planta de seis tanques esféricos.

Coeficiente de Descarga	$\left[\frac{L}{\text{min. cm}^2} \right]$
CD_1	0,8179
CD_2	0,8185
CD_3	0,9573
CD_4	0,9595
CD_5	1,0680
CD_6	1,1280

A planta pode apresentar comportamentos dinâmicos característicos de fase mínima e fase não mínima, os quais dependem dos valores de X_1 e X_2 . Há um zero de transmissão que se move ao longo do eixo real, apresentando valores positivos e

negativos. Conceitualmente, um sistema é dito de fase não mínima quando algum zero ou pólo encontra-se no semi-plano direito, e de fase mínima quando nenhum deles está nessa região (Paim, 2009). Sistemas de fase não mínima apresentam restrições intrínsecas ao processo, que resultam em resposta inversa ao controlar o sistema tanto em malha fechada, como em malha aberta e, conseqüentemente, resultam em uma dificuldade acentuada para estabilizar rapidamente esse sistema. Considerando que a alimentação direta para F_1 seja no tanque 4 e para F_2 seja no tanque 3, Aragão (2006) apud Paim (2009) estudou os efeitos de X_1 e X_2 na planta de seis tanques, cujos resultados são apresentados de acordo com a tabela 3.

Tabela 3 – Caracterização de Fases do Sistema.

Somatório das Frações X_1 e X_2	Característica do Sistema
$X_1 + X_2 > 1$	Sistema de Fase Mínima (Alimentação direta Predominante)
$X_1 + X_2 < 1$	Sistema de Fase Não Mínima (Alimentação direta Predominante)
$X_1 + X_2 = 1$	Ganho Multivariável Nulo (Não há controle)
$X_1 = X_2 = 0$ ou $X_1 = X_2 = 1$	Sistema Desacoplado

É importante salientar que, do modo como o sistema foi construído, quanto mais a soma de X_1 e X_2 chegar perto da unidade, mais difícil será o controle da unidade, pois há uma alta interação entre as duas malhas. F_1 e F_2 afetam ambos os tanques 3 e 4 simultaneamente, sendo que no somatório igual a 1 é impossível controlar cada saída independentemente, já que o determinante da matriz ganho é nulo, ou seja, a matriz é singular.

Sabendo que para esse sistema, X_1 e X_2 são parâmetros do processo, definiu-se ambos como 0,4, de modo que o sistema é de fase não mínima, o que apresenta maior desafio em termos de controle e dá espaço para uma maior gama de análises.

O objetivo do sistema é controlar os níveis dos tanques intermediários, h_3 e h_4 , utilizando como variáveis manipuladas F_1 e F_2 . As variáveis restantes, h_1, h_2, h_5 e h_6 , são consideradas nesse trabalho como sendo variáveis monitoradas.

4 Metodologia

O desenvolvimento do MPC foi realizado, à exceção da ferramenta que permite a obtenção dos parâmetros de sintonia, através da linguagem de programação Python 2.6, no ambiente de programação Eclipse SDK v.3.5.2. Python apresenta vantagens sobre outras linguagens de programação. É uma linguagem cuja clareza torna fácil o aprendizado e aplicação dos conceitos estudados. Além disso, analogamente à Java, uma linguagem já conceituada, Python pode ser orientado a objeto, o que traz uma série de benefícios, como agregação de módulos prontos ao projeto, reutilização de código e menor custo de desenvolvimento. Além disso, tem uma grande variedade de bibliotecas, interação com outras linguagens e é livre.

Quanto à análise de desempenho propriamente dita, o trabalho foi realizado majoritariamente no software MatLab v.5.3, que, assim como o Python, se apresenta como uma linguagem simples e objetiva. O desenvolvimento dos índices vale-se basicamente de análises estatísticas. Por estarem implementadas em MatLab, fez-se uso desta linguagem. As subseções a seguir apresentam passo a passo a implementação do MPC e dos índices.

4.1 Linearização do Modelo

A elaboração do MPC é feita em passos, iniciando com o desenvolvimento do modelo inserido no controlador, já que é o mesmo é dito como o elemento principal do MPC. Inicialmente, o modelo foi linearizado ao redor de um ponto, cuja validação foi feita valendo-se de equações fenomenológicas do sistema. O sistema foi linearizado em $F_{1ss} = F_{2ss} = 3.5 \frac{L}{min}$, com mudanças de F_1 e F_2 para 4,0, 3,0, 2,5 e 3,0 nos instantes $t = 50000, 100000, 150000$ e 200000 s, respectivamente. Os resultados da linearização podem ser vistos na Figura 7.

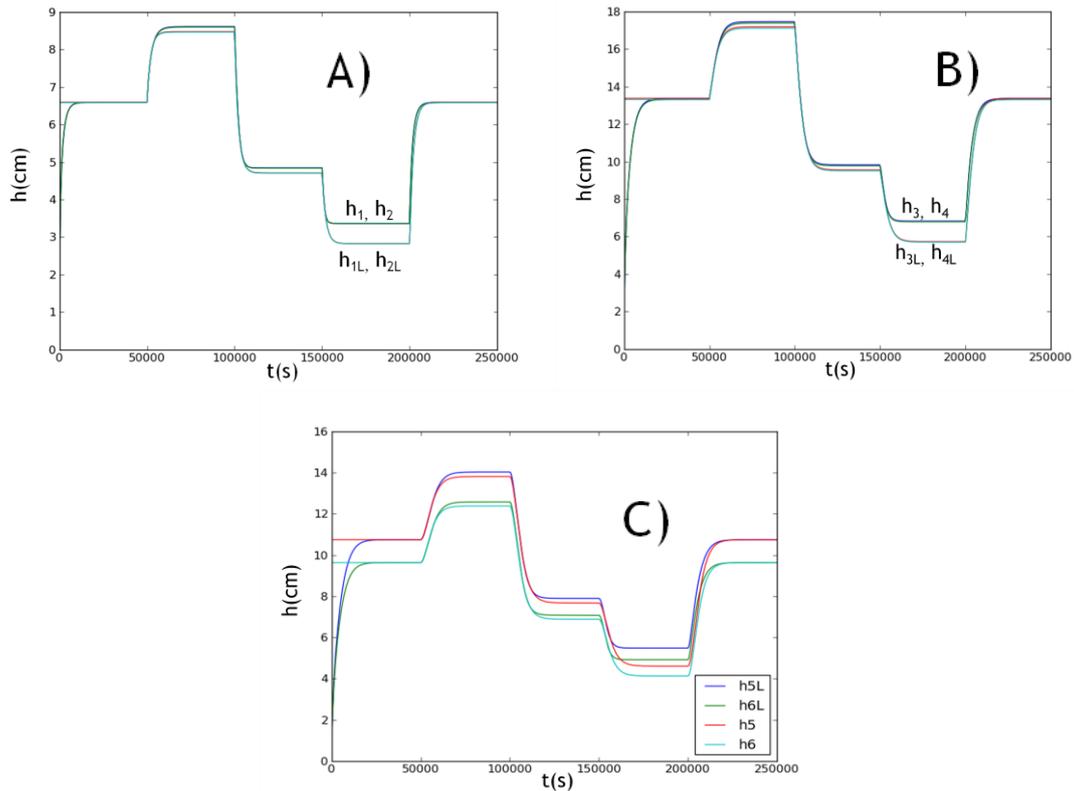


Figura 7 – Validação do modelo linear frente ao não linear para os tanques A) 1 e 2, B) 3 e 4 e C) 5 e 6.

Como pode ser visto até o instante $t = 50000$ s, o modelo linear e não linear não apresentam discrepância um em relação ao outro. Isso é devido à linearização ser em $F_{1ss} = F_{2ss} = 3.5$ e as alturas expressas no gráfico nesse período serem correspondentes a esse ponto em particular. A partir de 50000 s, entretanto, com a mudança de F_1 e F_2 pode-se notar uma diferença entre os dois valores, visto que a não linearidade inerente dos tanques acarreta em erro do modelo linearizado. Apesar dessa diferença, a dinâmica apresentada é semelhante, representando satisfatoriamente o sistema. É, pois, um modelo linearizado condizente com o sistema.

4.2 Parâmetros do MPC

Após a validação do modelo propriamente dito procedeu-se com a implementação do controlador em malha fechada, estabelecendo-se todos os parâmetros necessários ao MPC. Basicamente, trata-se dos limites das *hard* e *soft constraints* para todas as variáveis manipuladas e controladas, quando conveniente, e parâmetros de sintonia do controlador. Os limites das variáveis foram arbitrados

baseados nas dimensões dos tanques e nas vazões máximas e mínimas que as bombas fornecem. Tais restrições podem ser vistas na Tabela 4.

Tabela 4 – Restrições das Variáveis Manipuladas, Controladas e Monitoradas.

Variável		Tipo de restrição
h_3	<i>hard</i>	7 cm e 20 cm
h_4	<i>hard</i>	7 cm e 20 cm
F_1	<i>hard</i>	$1 \frac{L}{min}$ e $5 \frac{L}{min}$
F_2	<i>hard</i>	$1 \frac{L}{min}$ e $5 \frac{L}{min}$
h_1	<i>hard</i>	2 cm e 15 cm
	<i>soft</i>	3,5 cm e 15 cm
h_2	<i>hard</i>	2 cm e 15 cm
	<i>soft</i>	3,5 cm e 15 cm
h_5	<i>hard</i>	2 cm e 15 cm
	<i>soft</i>	3,5 cm e 15 cm
h_6	<i>hard</i>	2 cm e 15 cm
	<i>Soft</i>	3,5 cm e 15 cm

É importante salientar que os valores máximos arbitrados para as *soft constraints* e *hard constraints* das variáveis h_1, h_2, h_5 e h_6 tem o mesmo valor. Isso se deve puramente ao interesse de analisar o comportamento do sistema em uma região onde somente *hard constraints* exerçam suas restrições sobre o sistema.

Referente aos parâmetros de sintonia do MPC, valeu-se do chamado RPN, *robust performance number* (Trierweiler & Engell, 1997). O RPN representa uma medida do quanto difícil é para um dado sistema atingir o desempenho desejado de maneira robusta. Partindo dessa premissa, um controlador projetado com um pequeno valor de RPN é de grande interesse. A fim de se obter tal controlador, uma ferramenta foi desenvolvida pelo Grupo de Intensificação, Modelagem, Simulação, Controle e Otimização de Processos da UFRGS, GIMSCOP, chamado de *RPN Toolbox*. É possível obter através dessa metodologia as matrizes de escalonamento do sistema R e L , que associadas com os pesos das variáveis controladas Y e das variáveis manipuladas U , fornecem os parâmetros de sintonia do MPC propriamente dito, conforme as equações 21 e 22.

$$U_m = R^{-1} \times U \quad (21)$$

$$Y_m = Y \times L \quad (22)$$

Para o sistema estudado, os valores de R, L, Y e U são como se segue:

$$R = \begin{bmatrix} 1 & 0 \\ 0 & 1,0004 \end{bmatrix} \quad L = \begin{bmatrix} 0,32371 & 0 \\ 0 & 0,32817 \end{bmatrix} \quad Y = \begin{bmatrix} 0,76541 & 0 \\ 0 & 1,8484 \end{bmatrix} \quad U = \begin{bmatrix} 0,60887 & 0 \\ 0 & 1,4705 \end{bmatrix}$$

A partir dessa ferramenta, também podem ser inferidos os valores de tempo de amostragem, T_s , horizonte de predição, P , e horizonte do controle, M . Para o sistema estudado, os valores são os seguintes:

$$T_s = 100 \text{ s} \quad P = 160 \times T_s \quad M = 60 \times T_s$$

Sintonizando o controlador, é interessante corroborar essa sintonia. Desse modo, o MPC foi submetido a mudanças de set-point e distúrbios do tipo degrau, de modo a avaliar seu comportamento servo e regulatório. Os resultados podem ser vistos na Figura 8.

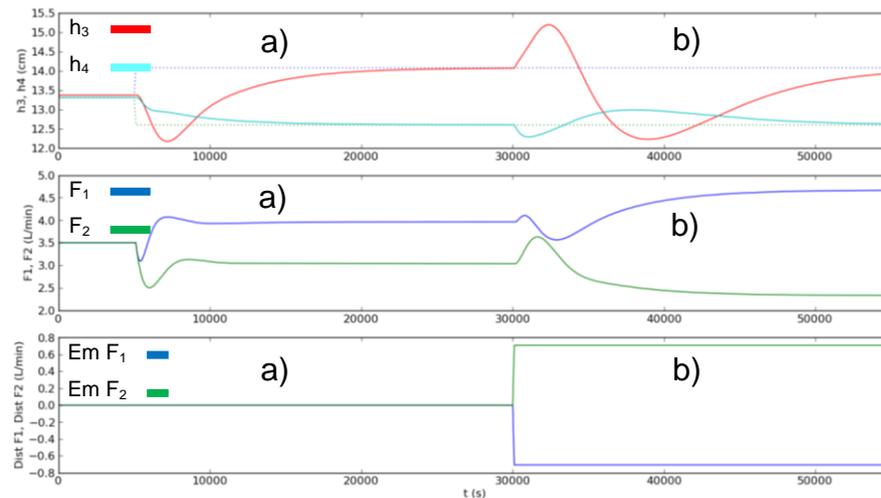


Figura 8 – Desempenho a) servo e b) regulatório do MPC.

4.3 Implementação dos Índices

Na seção 2.2, três índices foram apresentados, com o intuito de avaliar o desempenho de um controlador: VR , UE e DM . A fim de implementá-los, uma metodologia particular foi estabelecida.

4.3.1 Variabilidade Relativa (VR)

O índice VR vale-se de um valor de referência, σ_{REF}^2 , que deve ser determinado ou arbitrado para as variáveis controladas. Considerou-se para o MPC estudado que a variabilidade deveria ser referente ao erro em relação aos *set points*, $Y - R$, aplicado para uma situação de referência pré-estabelecida, definido como σ_{REF}^2 . Para tanto, a seguinte metodologia foi aplicada.

A proposta para a determinação desses valores consiste em simular um sistema submetido a distúrbios de carga e de saída aleatórios com distribuição

normal, mantendo as faixas das variáveis monitoradas e *set point* fixados, levando em consideração, ainda, tanto para o MPC como para a planta, modelos lineares. O objetivo é, partir de uma série de simulações desse sistema em excelentes condições, e, então, determinar a distribuição de variâncias dentro de uma amostragem de inúmeras simulações. Tendo essa distribuição, é possível obter-se um valor de variância mínima, σ_{MIN}^2 , arbitrando um intervalo de confiança. Tal metodologia caracteriza-se como o método de Monte Carlo (Hromkovic, 2001).

Cada simulação tem a duração da janela necessária para a obtenção da variabilidade das saídas da planta. A janela escolhida deve ser capaz de representar um sistema que tenha sentido os efeitos das variáveis de entrada na sua totalidade e reagido aos distúrbios provocados. Sabendo que o horizonte de predição é dito como sendo aproximadamente 80% do tempo de assentamento, arbitrou-se para o experimento, uma janela igual a três vezes o horizonte de predição. Os valores de janelas são usualmente arbitrados e não há praticamente referências bibliográficas referente a esse tópico em particular.

Valeu-se de um total de 21 simulações, onde o modelo da planta e do MPC foram os mesmos, lineares, caracterizando uma situação ótima de operação e, conseqüentemente, uma menor variabilidade associada. Cada simulação tem a duração de 36 vezes o horizonte de predição, obtendo um total de 252 variâncias distintas para cada uma das variáveis controladas e monitoradas do sistema, que foram representadas na forma de histogramas. Sabendo que o distúrbio na carga é normal, tal efeito se propaga na planta, obtendo saídas que apresentam uma distribuição de valores próxima à normal. Ao analisar a variância desses dados, basicamente elevam-se todos os valores ao quadrado, ponderados pela quantidade de valores. Uma distribuição estatística de dados normais elevada ao quadrado torna-se uma distribuição chi-quadrada, que é uma particularização da distribuição *gamma*. Como os dados não são normais propriamente ditos, optou-se por, através do software MatLab, ajustar os dados apresentados para cada variável por uma curva de distribuição *gamma*, como pode ser visto na Figura 9, que acarretaram em resultados mais coerentes do que quando ajustadas as curvas para uma distribuição chi-quadrada.

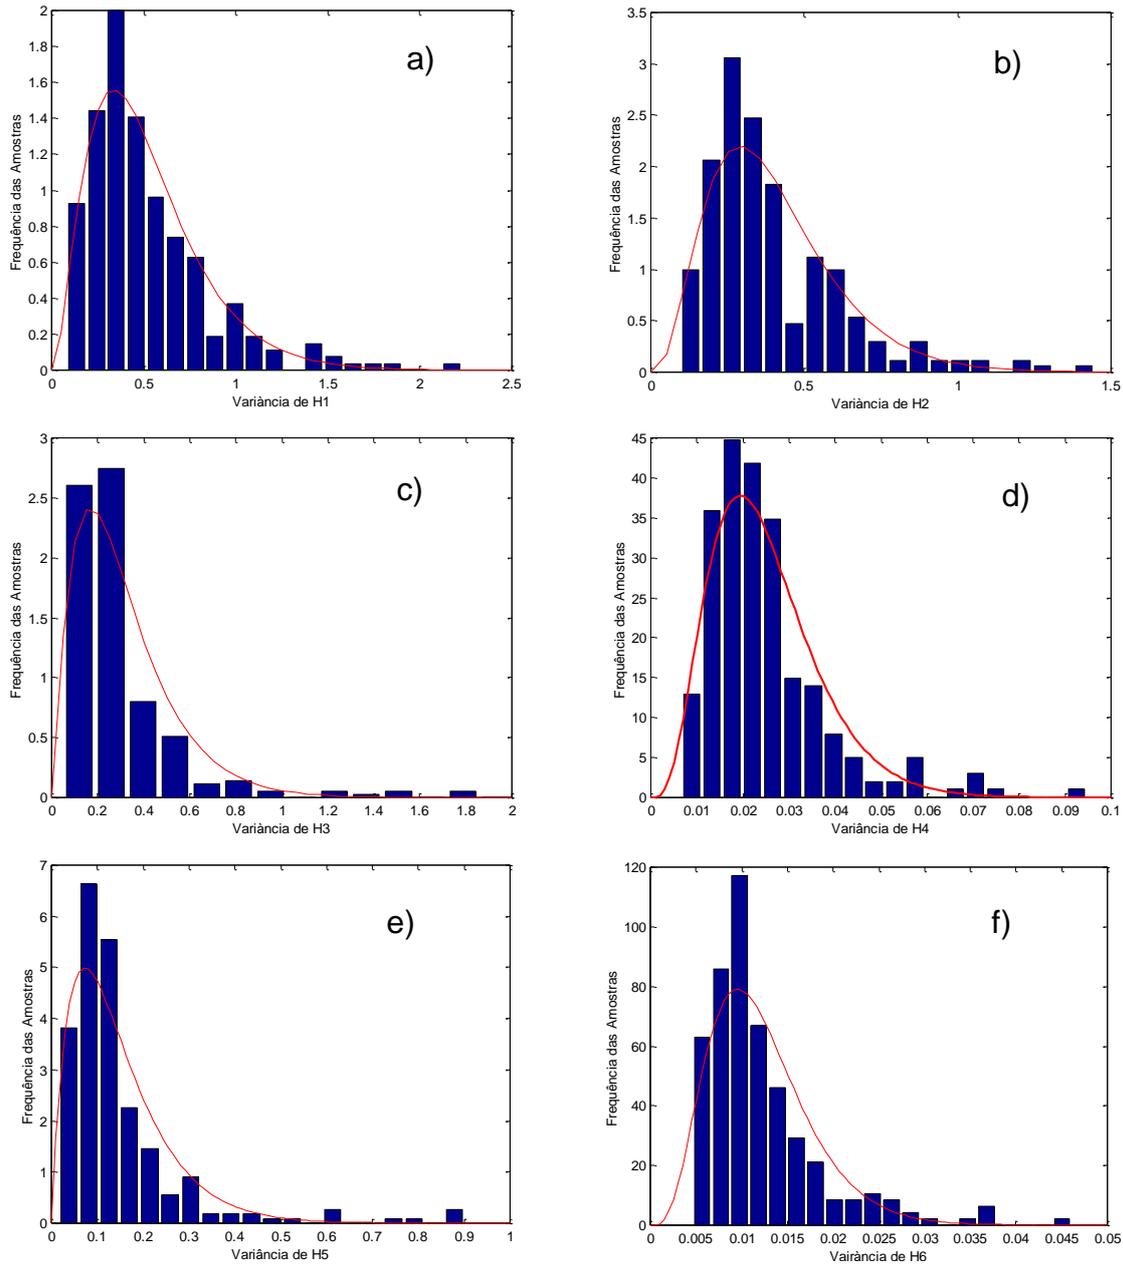


Figura 9 – Distribuição das variâncias dos estados do sistema, para a) h_1 , b) h_2 , c) h_3 , d) h_4 , e) h_5 e f) h_6 .

A partir dessas distribuições determinaram-se os valores de referência de variância. Arbitrando um intervalo de confiança de 95%, ou seja, garantindo que somente 5% dos valores serão menores que essa variância, determinaram-se as variâncias correspondentes. Os valores podem ser vistos na Tabela 5.

Tabela 5 – Variâncias de referência para as saídas da planta.

Estado	σ_{REF}^2
h_1	0,1368
h_2	0,1292

h_3	0,0606
h_4	0,0093
h_5	0,0207
h_6	0,0046

4.3.2 Utilização Efetiva (UE)

A utilização do índice UE no sistema apresentado na seção 3 é discutível. O índice tem um viés muito mais ligado à questão operacional. Em se tratando de grandes sistemas de controle, com dezenas de controladores atuando, cada qual com seu número de variáveis manipuladas e controladas, onde os objetivos operacionais são bem definidos, tal análise é factível e importante, de modo a verificar qual a porcentagem de controladores que, seja por não estarem ativos, seja pelas suas manipuladas não estarem ativas, seja por essas manipuladas estarem saturadas, não estão operando bem.

Esse índice não foi avaliado, visto que o mesmo só faria sentido caso a planta fosse operada de fato e não fossem simplesmente feitas análises através de simulações. Além disso, em se tratando da definição do índice propriamente dita, não faz sentido, em simulação, falar em MPC ligado ou desligado, assim como variáveis manipuladas ativas ou inativas.

4.3.3 Desempenho do Modelo (DM)

O índice DM é facilmente obtido a partir de uma avaliação direta da variabilidade da predição do modelo em relação à variabilidade real obtida. Utilizando essa análise em conjunto com o VR , é possível determinar se o modelo está predizendo algo condizente com a realidade e se, além disso, o está fazendo com uma baixa variabilidade. A metodologia empregada é simples. Avalia-se para um tempo de simulação pré-determinado uma janela de dados e, a partir dessa janela, determina-se a variância ao longo do tempo para as saídas reais da planta e para os valores preditos pelo MPC. O valor arbitrado é o mesmo da seção 4.3.1, três vezes o horizonte de predição.

5 Discussão e Resultados

A partir da metodologia apresentada na seção 4, foi possível a implementação do MPC e a realização de testes, a partir de simulações com a planta não-linear. O diagrama de blocos correspondente ao MPC associado com a planta é mostrado na Figura 10.

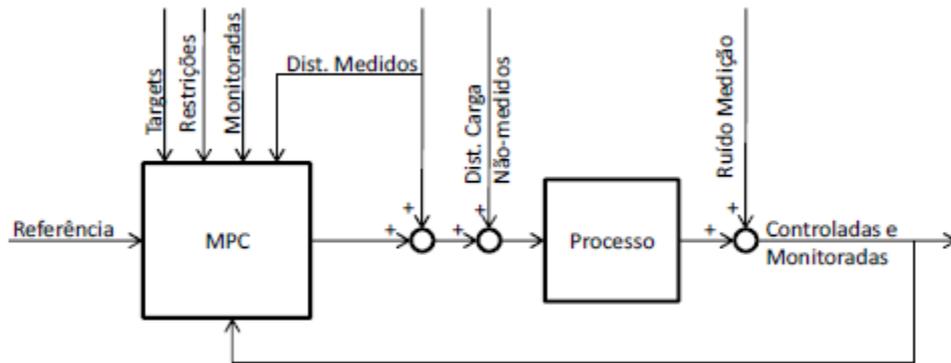


Figura 10 – Diagrama de blocos do processo associado com o MPC.

Inicialmente, para um *set point* fixado em $h_3 = 13,37 \text{ cm}$ e $h_4 = 13,31 \text{ cm}$, correspondentes aos níveis estacionários para $F_1 = F_2 = 3,5 \frac{\text{L}}{\text{min}}$, verificou-se o comportamento do sistema, como pode ser visto na Figura 11.

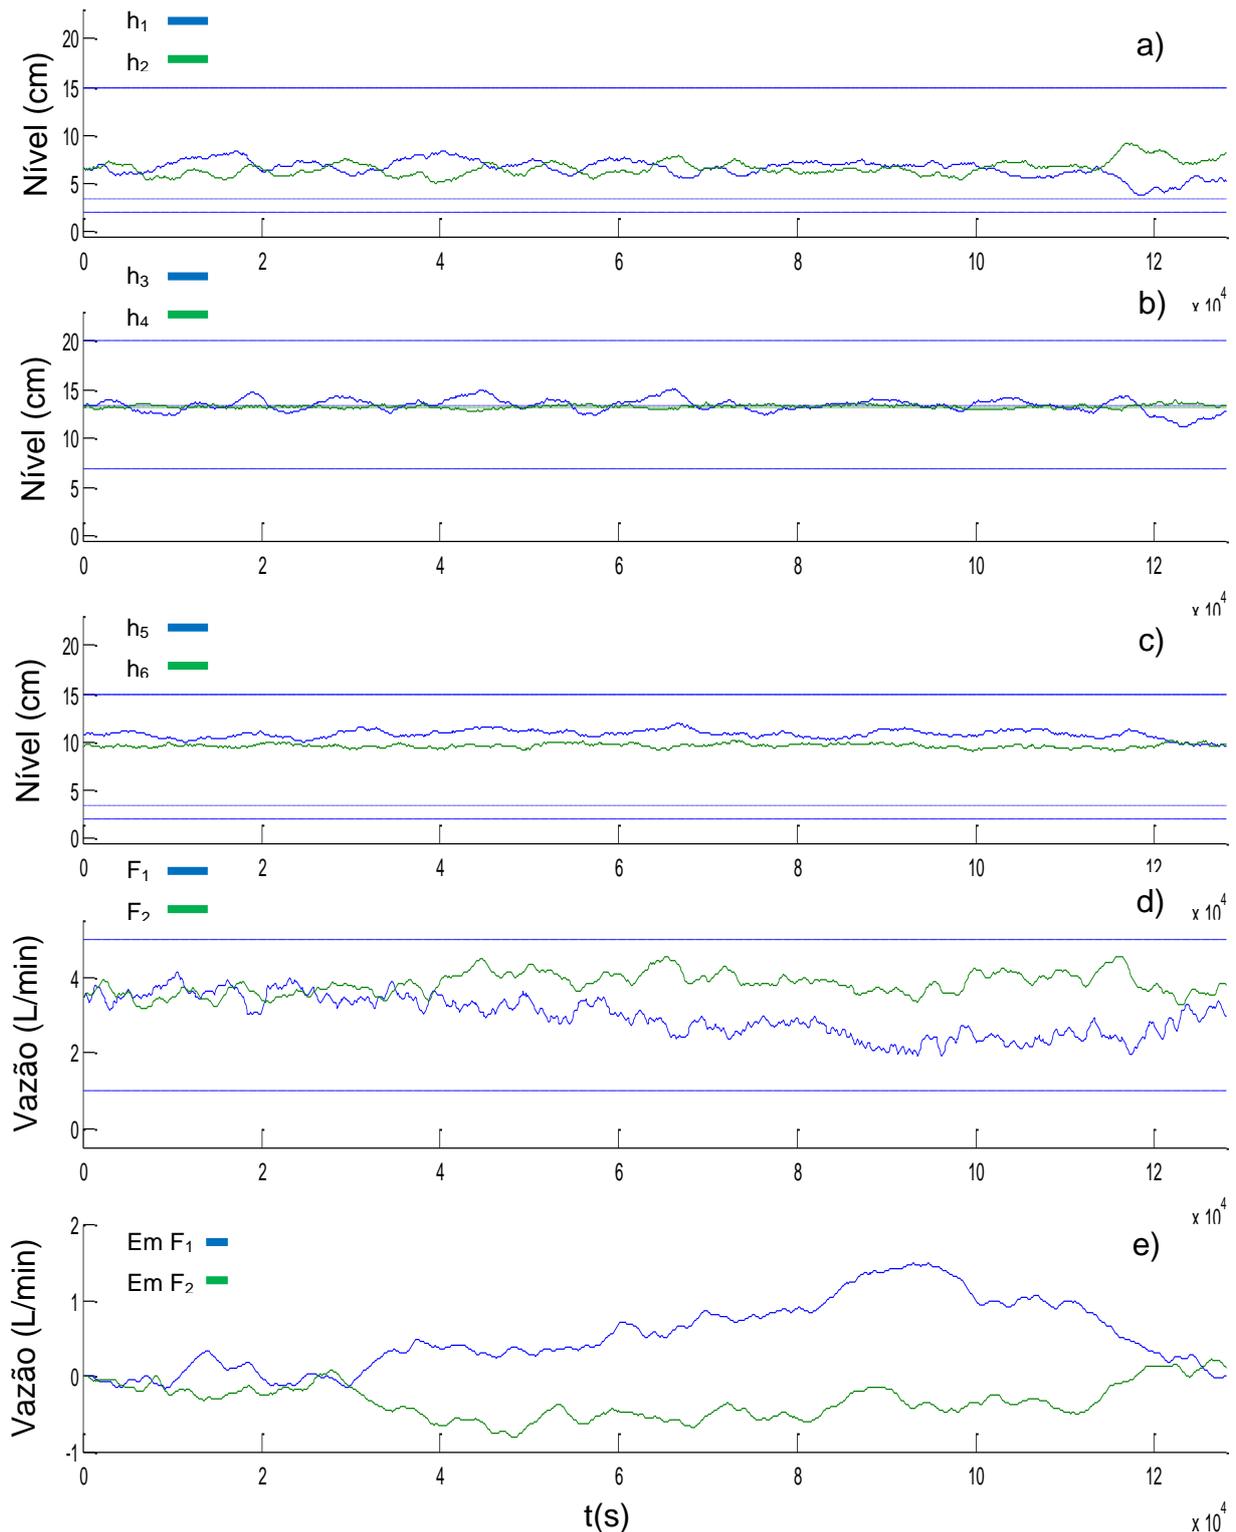


Figura 11 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para *set point* constante de $h_3 = 13,37 \text{ cm}$ e $h_4 = 13,31 \text{ cm}$.

As linhas tracejadas indicam a posição das *hard constraints* e as linhas pontilhadas, as das *soft constraints*. h_3 e h_4 estão sendo controladas para o *set point* proposto, apesar de h_3 apresentar uma maior variabilidade. Como o restante das

variáveis monitoradas e manipuladas está dentro dos seus limites, a ação de controle é efeito exclusivamente dos distúrbios exercidos nas cargas. Os índices correspondentes a essa situação podem ser vistos nas Figura 12 e Figura 13.

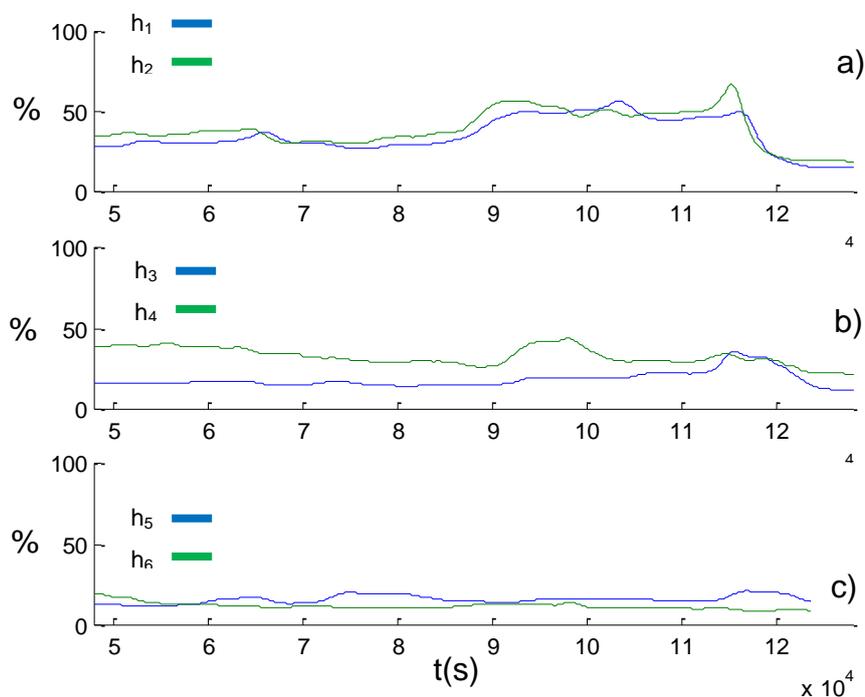


Figura 12 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

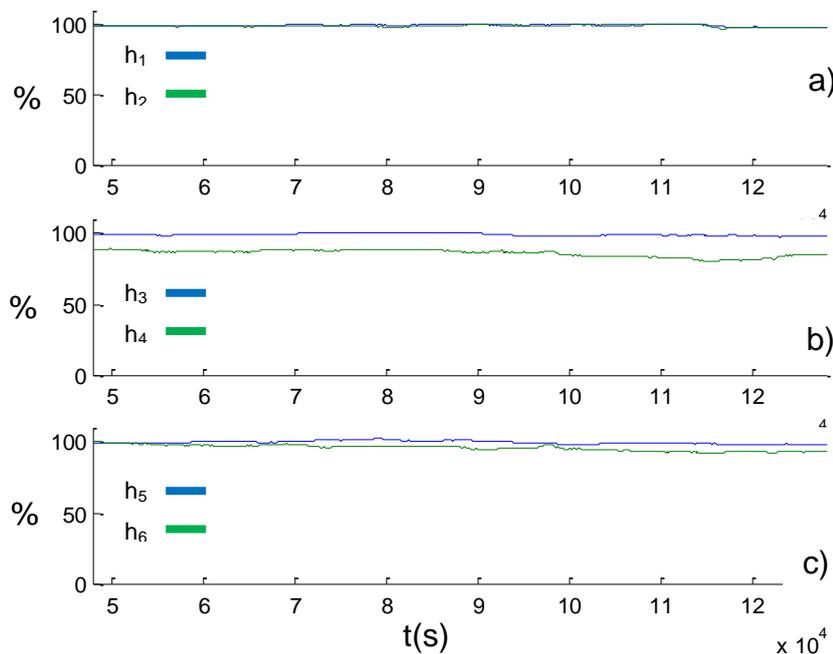


Figura 13 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

A partir dos resultados da Figura 12, pode-se ver que o índice referente à variabilidade relativa, VR, apresenta valores baixos. Isso se deve à σ_{REF}^2 determinada, que é certamente muito menor que a variabilidade obtida. Os testes

para determinação da variância de referência foram realizados com uma planta cujo modelo é linear, ao passo que o modelo real é não-linear. Desse modo, em qualquer local fora do ponto da linearização, o modelo linear tem um erro associado na predição que afeta a ação de controle e, logo, aumenta a variabilidade. Para esse cenário, o efeito não é tão significativo, pois a planta opera ao redor do ponto onde houve a linearização. Ainda assim, o VR sofre nessa situação.

Apesar de poder concluir que a planta encontra-se numa situação pior que a referência, não há muito mais que possa ser inferido. O VR apresenta uma grande desvantagem, é sensível aos distúrbios. Como os distúrbios são de origem aleatória, e realmente são assim na indústria, é muito difícil garantir quem é responsável pela mudança do índice, os distúrbios ou o controlador. É possível claramente inferir que o desempenho do controlador está abaixo do esperado, mas não é possível mensurar isso, a fim de determinar um limite claro entre desempenho bom e ruim.

A partir dos resultados da Figura 13, é possível ver que a variabilidade das saídas da planta preditas pelo MPC frente às reais saídas, o DM, apresenta resultados mais próximos de 100% do que o VR. Isso indica que a predição do modelo é precisa, representando as saídas da planta real. Se, contudo, somente esse índice for levado em consideração para análise do desempenho do MPC, resultados errôneos são obtidos. Apesar de o modelo estar prevendo muito bem as saídas do processo, as ações de controle correspondentes estão muito aquém do desempenho estabelecido como referência. Uma análise conjunta dos índices, logo, é a melhor saída, a fim de obter resultados mais conclusivos.

Para um segundo cenário, foi considerada a mudança de *set point* das variáveis h_3 e h_4 durante a simulação, a fim de avaliar a resposta do controlador. Trata-se de regiões de operação agora completamente fora da região da linearização, podendo até mesmo atingir restrições, que fatalmente reduzirão o desempenho do MPC. Os resultados podem ser vistos nas Figura 14, Figura 15 e Figura 16.

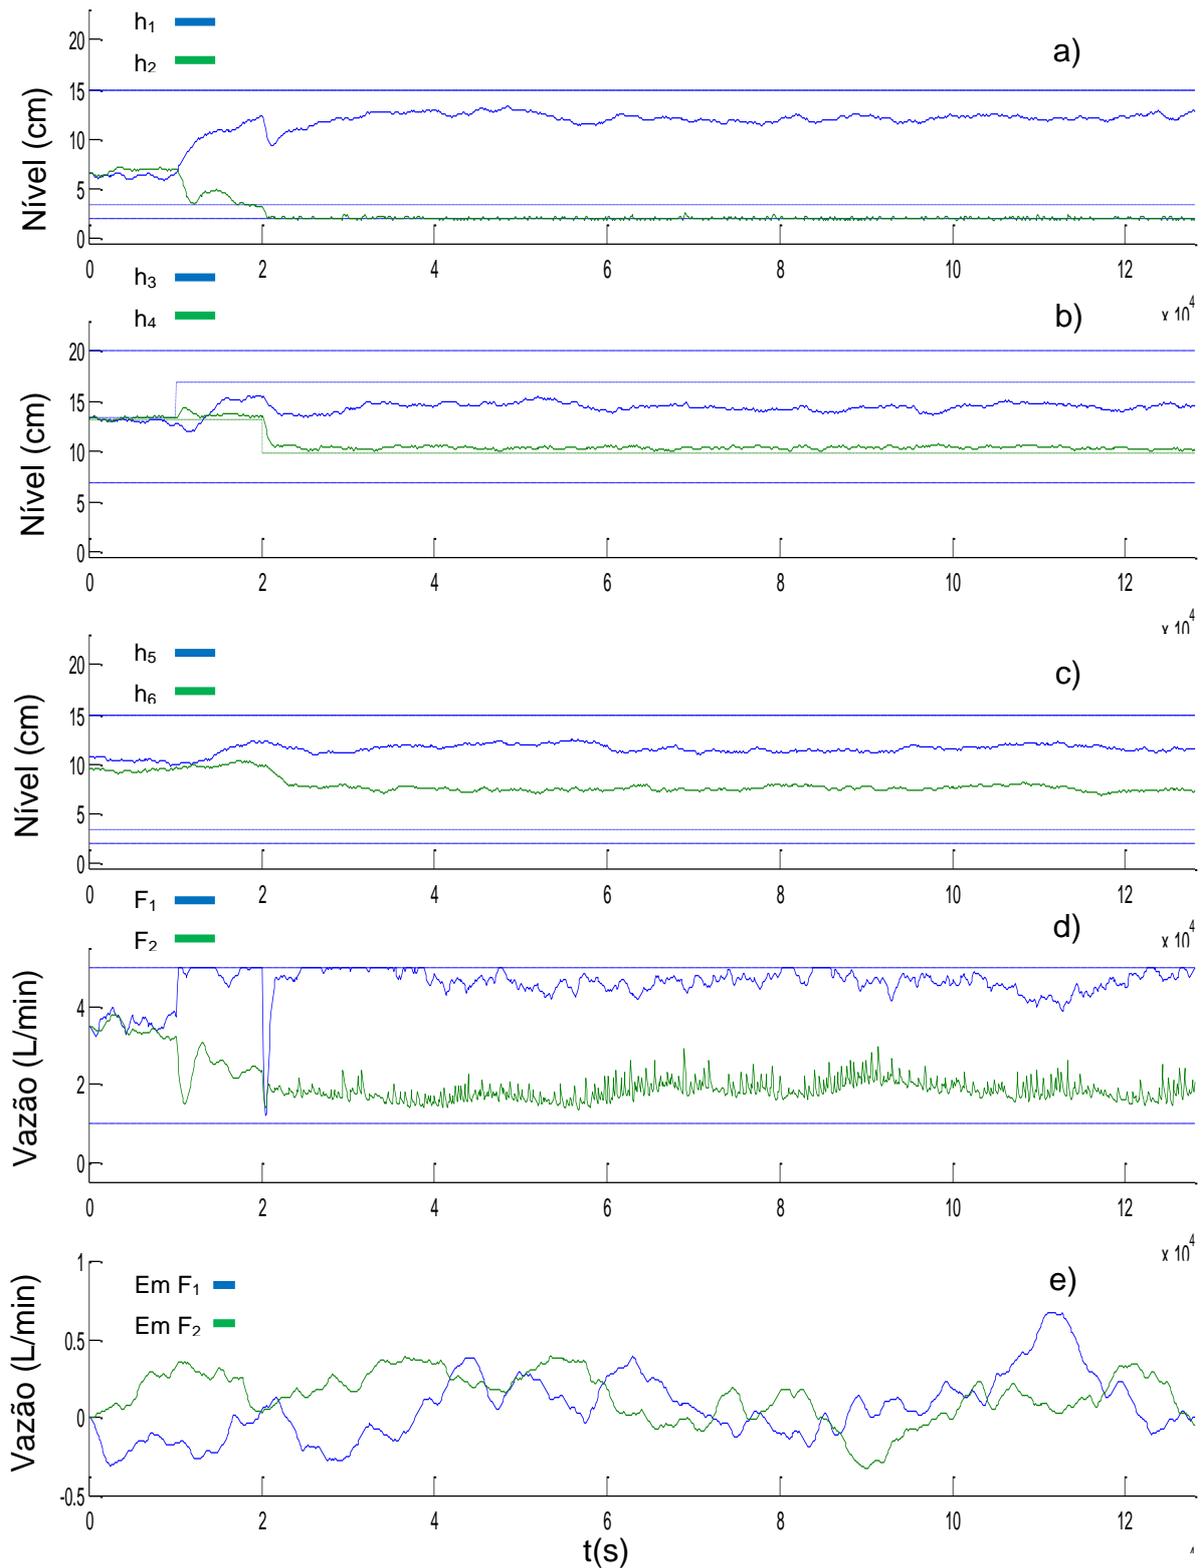


Figura 14 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para uma mudança no set point de 3,5 cm em h_3 em $t = 100 \times T_s$ s e -3,5 cm para h_4 em $t = 200 \times T_s$ s.

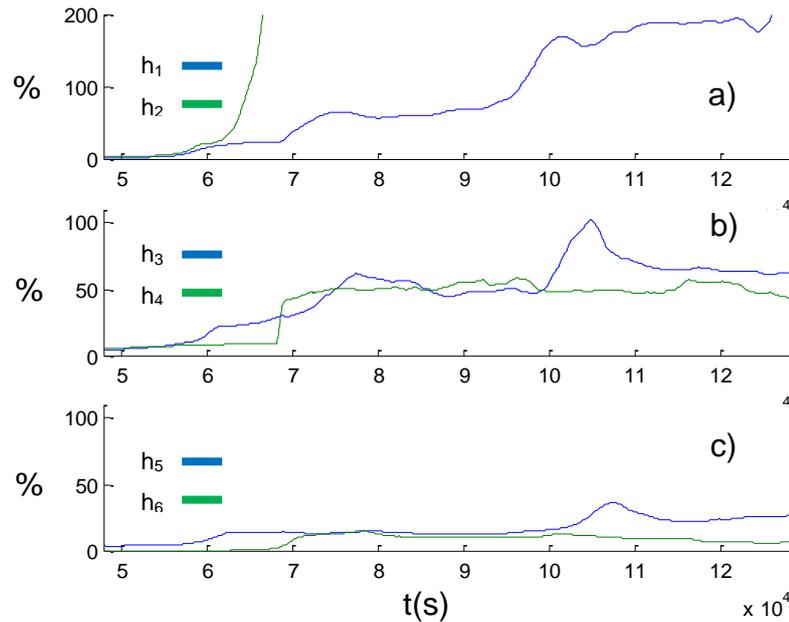


Figura 15 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

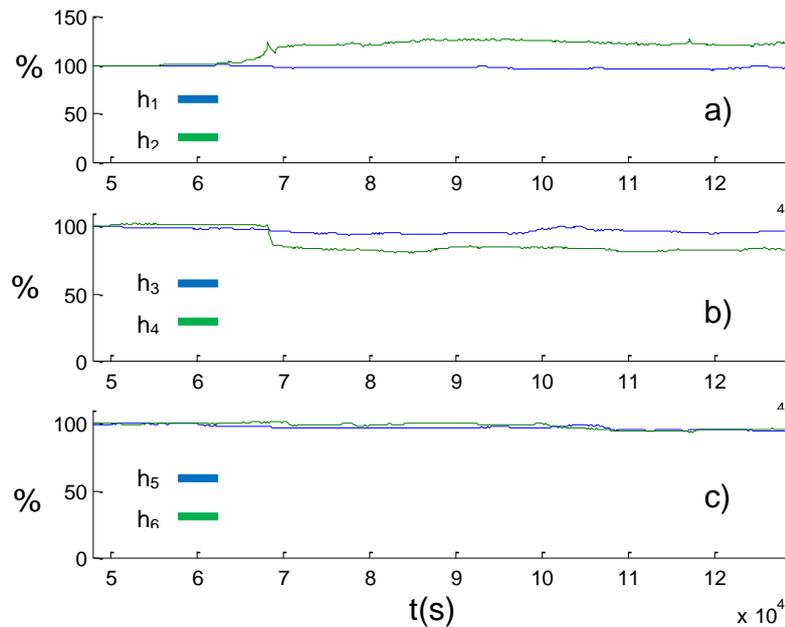


Figura 16 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

Para o segundo cenário, é interessante observar que, devido à h_2 e F_1 terem atingido a restrição, houve uma queda no desempenho do controlador, visto que nenhum dos dois *set points* conseguiu ser atingido. Esse impacto, entretanto, é de difícil análise através dos índices. Atingindo a restrição, o estado h_2 praticamente para de variar. Assim, como na fórmula a variabilidade real está no denominador, o VR tende a valores muito maiores que 100%, não estabilizando para o tempo de simulação. Analogamente, h_1 também chega a um patamar com uma menor

variabilidade, cujo VR chega a 200%, em virtude da saturação de F_1 . Em se tratando das variáveis que atingem suas respectivas restrições, a aplicação do VR é inconclusiva, visto que não há como analisar a situação apresentada na Figura 15a.

Uma causa comum de queda no desempenho em controladores é a sintonização pobre do controlador. Partindo desse princípio, foi também analisado o efeito da sintonia do controlador no sistema e nos índices. Para tanto, as matrizes Y e U , obtidas a partir do *RPN Toolbox* apresentado na seção 4.2, foram alteradas. Essas matrizes representam, respectivamente, o peso dado a cada variável controlada no algoritmo de otimização e o peso dado a cada variável manipulada no algoritmo de otimização. Os valores atuais das matrizes Y e U são conforme se segue:

$$Y = \begin{bmatrix} 0,76541 & 0 \\ 0 & 1,8484 \end{bmatrix} \quad U = \begin{bmatrix} 0,60887 & 0 \\ 0 & 1,4705 \end{bmatrix}$$

Sabendo que Y trata de h_3 e h_4 , pode-se ver que é dada mais importância ao controle de h_4 pelo algoritmo de otimização. Analogamente, a variável F_1 tem uma maior liberdade para variar que F_2 . O teste foi realizado mantendo essa relação, somente aproximando os pesos para valores mais próximos um do outro. Os novos Y e U são dados conforme se segue:

$$Y = \begin{bmatrix} 0,5 & 0 \\ 0 & 1,4 \end{bmatrix} \quad U = \begin{bmatrix} 0,3 & 0 \\ 0 & 1,1 \end{bmatrix}$$

Comparando a Figura 17 com o controlador apresentado na seção 4.2, pode-se inferir que a resposta de ambos é semelhante. Devido à dinâmica do sistema ser muito lenta, entretanto, uma pequena variação na resposta acarretará em uma grande perda de desempenho, como pode ser visto nas figuras 18 a 23.

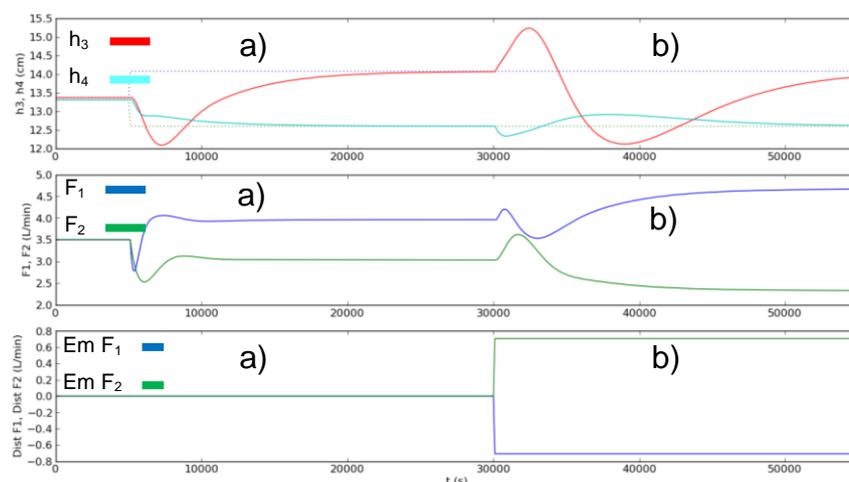


Figura 17 – Desempenho a) servo e b) regulatório do MPC quando mal sintonizado.

Ao alterar os valores das matrizes Y e U , o controle passa a ser bem mais instável do que o controlador projetado pelo *RPN toolbox*, caracterizando um controlador com um pior desempenho.

Tomando como referência os testes realizados anteriormente, as simulações são análogas para o controlador mal sintonizado, podem ser vistos nas Figura 18, Figura 19 e Figura 20 para o terceiro cenário, *set point* constante ao longo da simulação, e nas Figura 21, Figura 22 e Figura 23 para o quarto cenário, mudanças de *set point* nas variáveis h_3 e h_4 , os resultados.

Comparando os dois primeiros cenários com os dois últimos é possível observar que os valores de VR são ligeiramente mais baixos ao mal sintonizar o controlador, indicando a queda de desempenho já esperada. Como o padrão dos distúrbios é diferente nos dois casos, entretanto, não é possível detectar claramente se tais valores são indícios de um menor desempenho necessariamente ou de distúrbios mais amenos. Ainda assim, a análise é, portanto, assaz confusa e inconclusiva.

É interessante de se observar, contudo, que determinadas variáveis sofrem mais com a má sintonização do controlador. As variáveis h_1 e h_2 , por exemplo, são dependentes pura e exclusivamente de F_1 e F_2 , respectivamente. Em função da má sintonia, o controlador vai apresentar uma maior variabilidade nessas manipuladas, que tem efeito direto na variabilidade das controladas. Tal fato fica claro ao comparar as figuras 12 e 15 com as figuras 18 e 21.

O VR, em suma, não pode ser utilizado quando se deseja realizar uma comparação entre dois controladores distintos, visto que, como os distúrbios comportam-se de uma maneira aleatória, dois controladores certamente não terão o mesmo padrão de distúrbios e, logo, não há garantia de quem está influenciando o índice mais, o distúrbio ou o controlador propriamente dito. É perfeitamente possível, entretanto, sabendo um valor de variância de referência, determinar o quão bom o controlador está em relação à referência. Tal análise é possível, pois tal valor base é usualmente independente do distúrbio, devido à maneira como foi determinada. Para o trabalho apresentado, o método de Monte Carlo permitiu escolher uma variância mínima que, dado o seu intervalo de confiança, é válida para qualquer distúrbio.

Em relação ao DM para esses cenários, os valores mantêm-se praticamente os mesmos, independente da simulação, havendo uma pequena discrepância somente

na predição de h_4 , devendo ser analisado mais a fundo o modelo utilizado e as considerações propostas. O DM revela de maneira eficiente a qualidade da predição do modelo. Entretanto, como não possui nenhuma informação quanto à ação de controle do MPC, não deve ser utilizado exclusivamente no diagnóstico de desempenho do MPC.

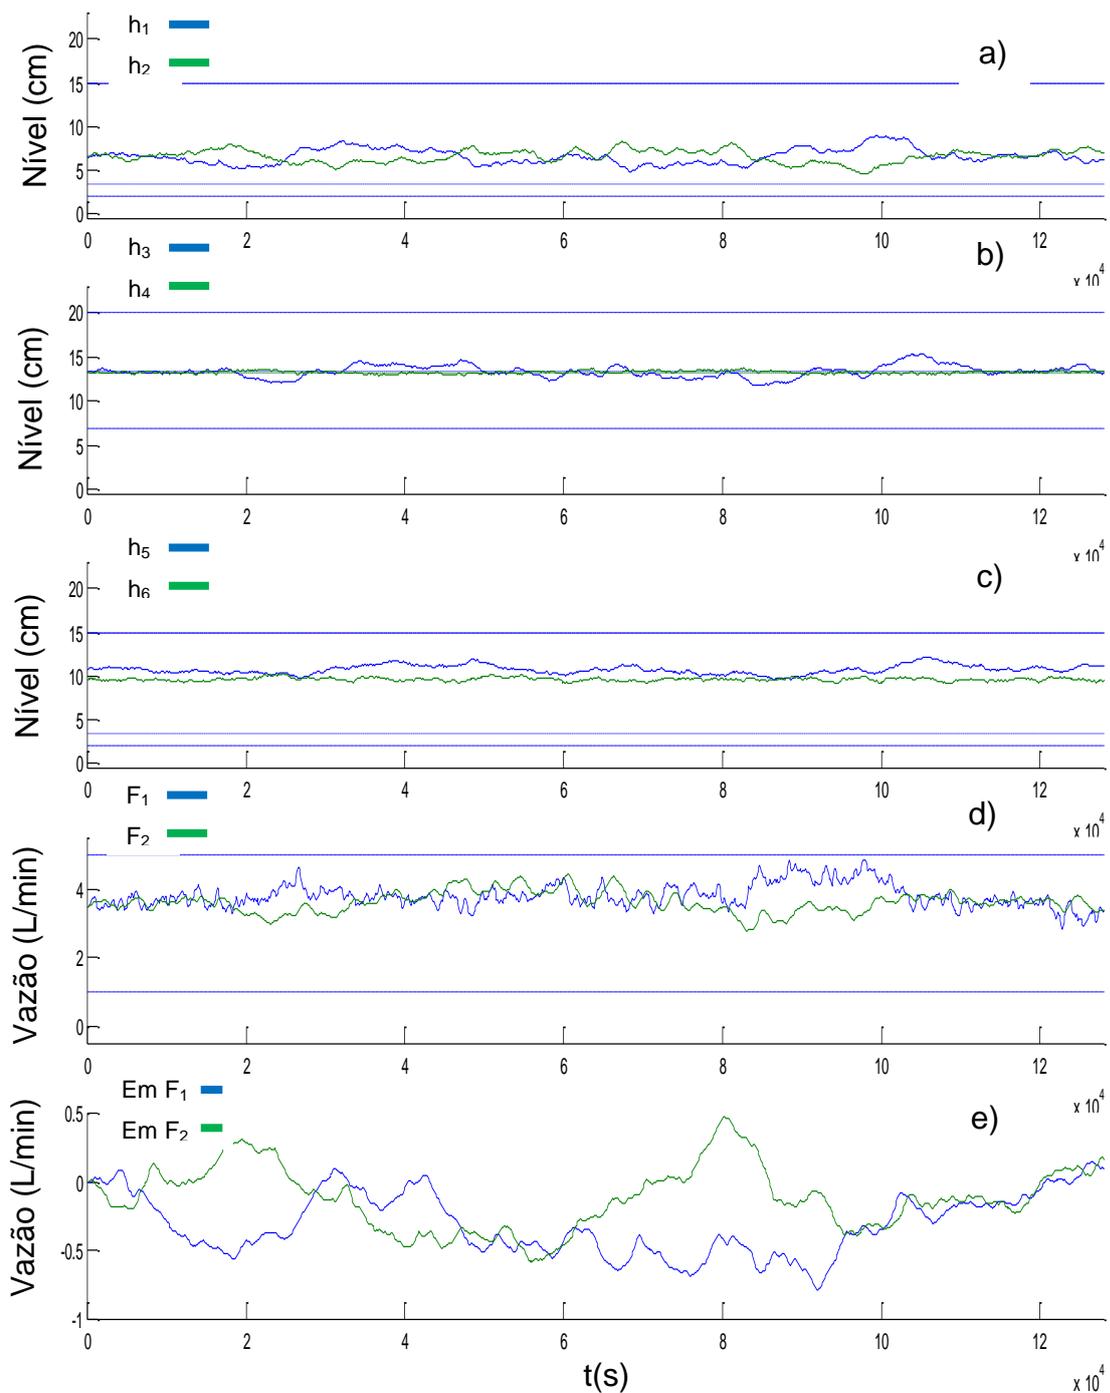


Figura 18 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para *set point* constante de $h_3 = 13,37 \text{ cm}$ e $h_4 = 13,31 \text{ cm}$, com um controlador mal sintonizado.

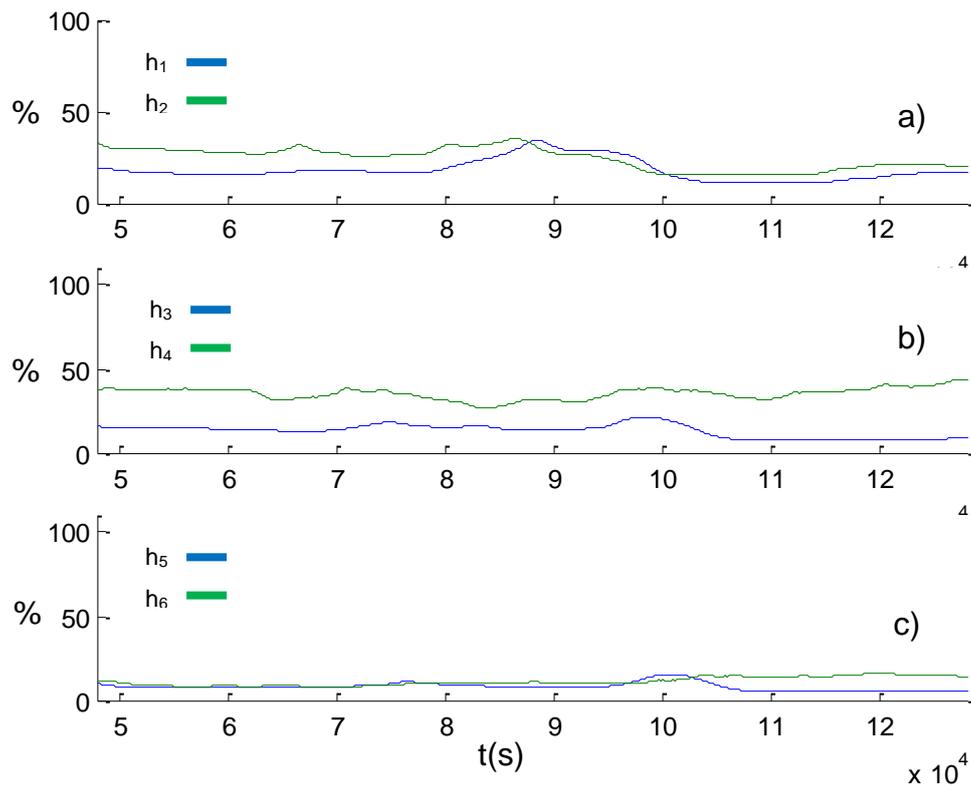


Figura 19 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

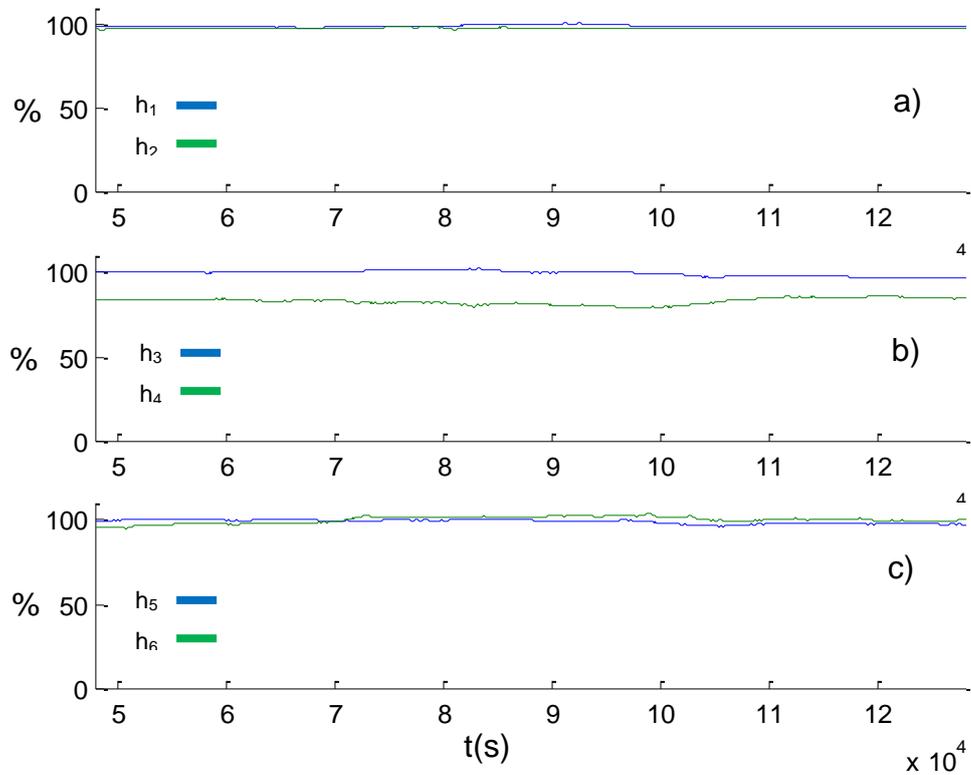


Figura 20 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

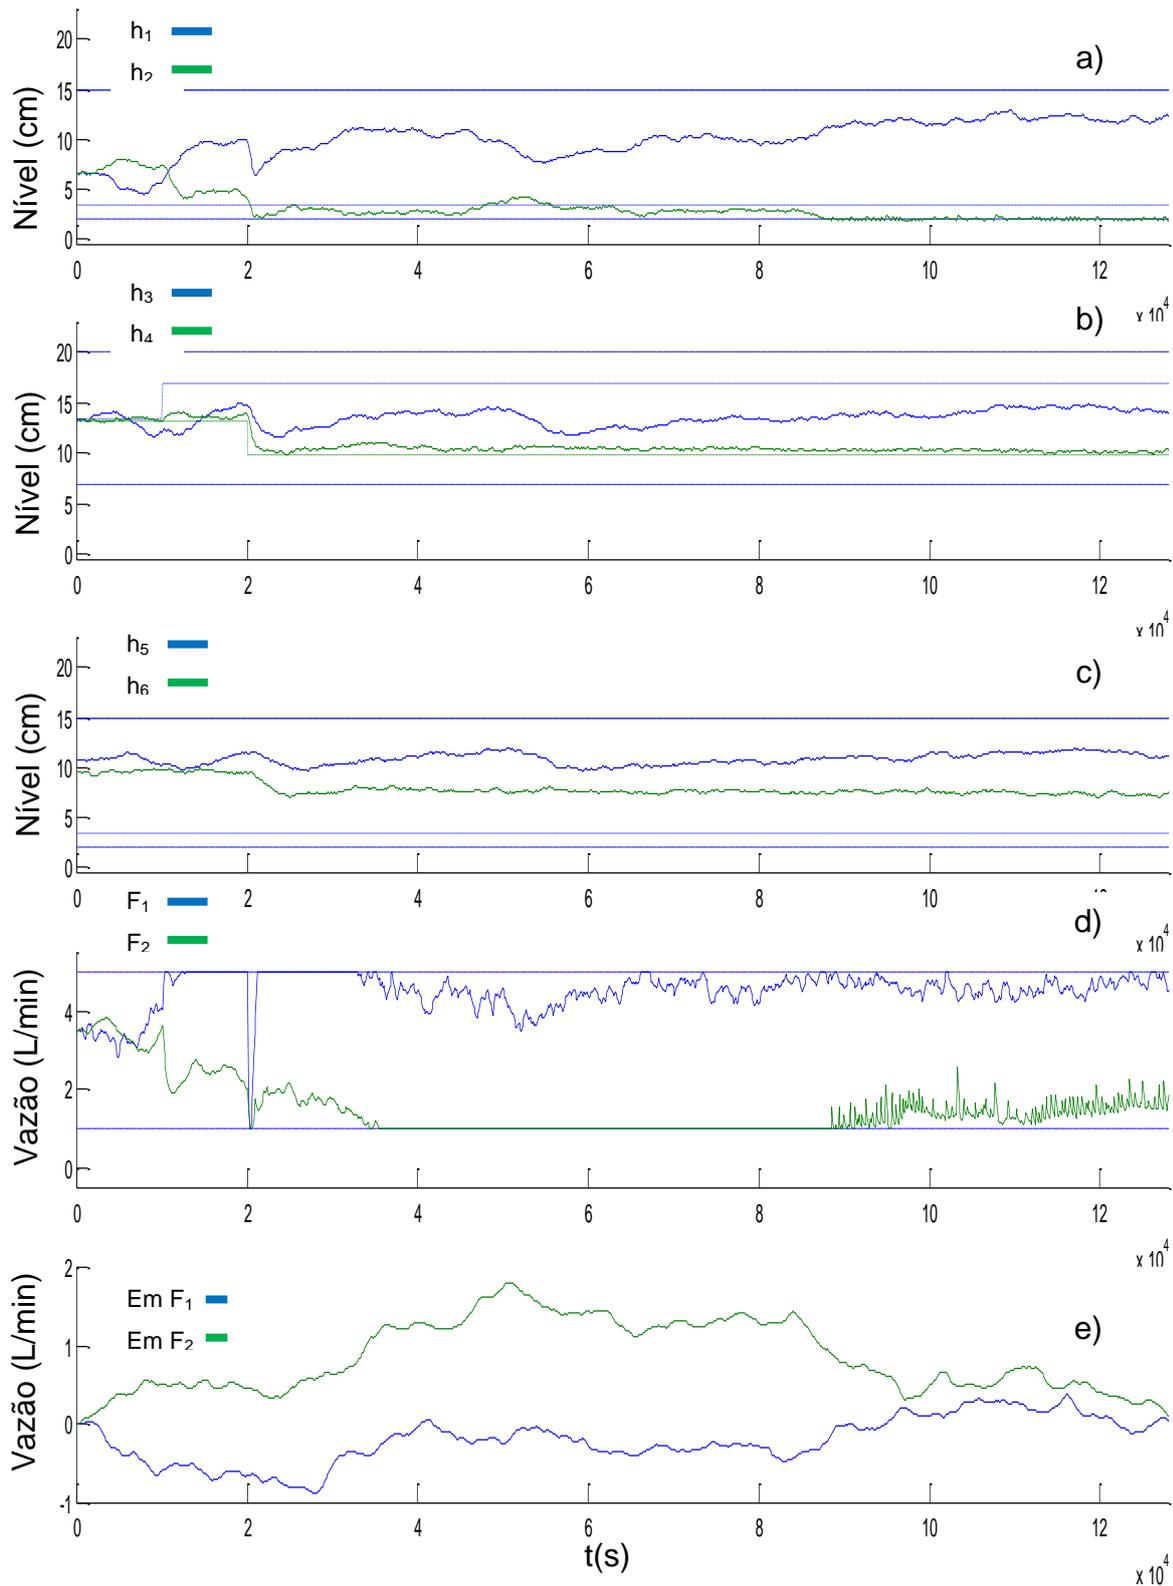


Figura 21 – Simulação da planta de seis tanques esféricos para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 , para as manipuladas d) F_1 e F_2 e para os distúrbios e) em F_1 e F_2 , para uma mudança no set point de 3,5 cm em h_3 em $t = 100 \times T_s$ e -3,5 cm para h_4 em $t = 200 \times T_s$, com um controlador mal sintonizado.

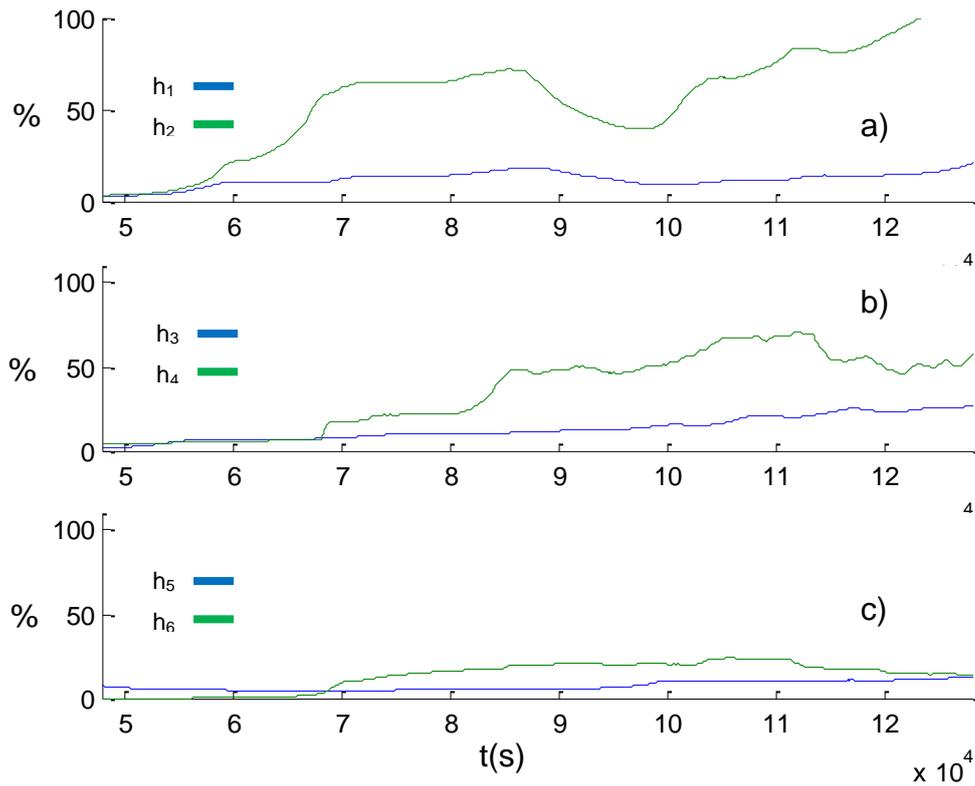


Figura 22 – Variabilidade Relativa (VR) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

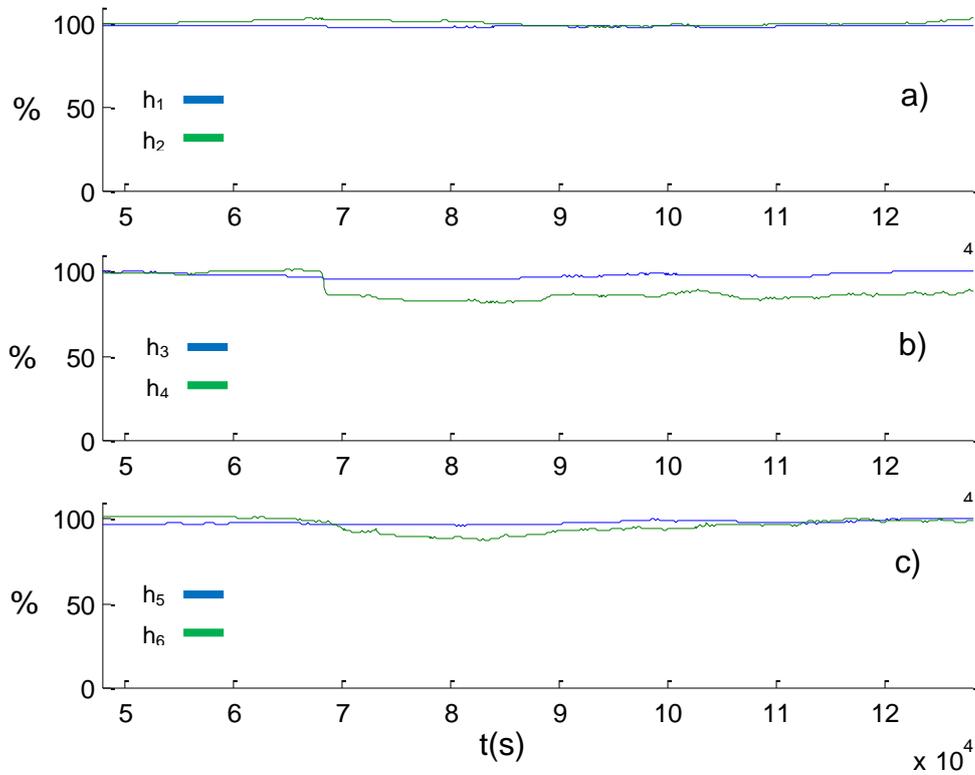


Figura 23 – Desempenho do Modelo (DM) para os estados a) h_1 e h_2 , b) h_3 e h_4 e c) h_5 e h_6 .

6 Conclusão

O MPC é uma ferramenta que possibilita a predição do comportamento de um sistema e atuação eficiente sobre o mesmo, devido à utilização de um modelo utilizado para prever o efeito das variáveis manipuladas na saída do sistema. É versátil e de fácil aplicação.

Para o caso estudado, o MPC implementado é linear. Tal linearidade afeta a predição do modelo, acarretando em erros associados. Tais erros, entretanto não são significativos frente à representação correta da dinâmica do processo, fator esse que mostrou-se muito mais importante. Mesmo em regiões fora da região de linearização, o valor das saídas previstas teve uma discrepância mínima em relação às saídas reais.

A análise estatística realizada para determinação das variâncias de referência para cada variável foi de grande valia e aplicabilidade, visto que, excetuando situações onde as variáveis controladas atingiam as suas restrições, os índices mantiveram-se abaixo de 100%, sendo, logo, coerentes.

Dentre os índices apresentados, o VR é demasiadamente simples e incorre em algumas dificuldades quanto à análise. Em virtude de ser dependente dos distúrbios, a análise comparativa entre duas simulações distintas é praticamente inviável, visto que não há como garantir que as discrepâncias observadas no VR são correspondentes aos distúrbios ou ao controlador propriamente dito. É possível, entretanto, comparar as variâncias obtidas em função da referência calculada para cada variável, podendo inferir se o controlador está operando de maneira eficiente em relação a uma condição ótima de operação. Em suma, aplicando o VR, não há a possibilidade de se realizar comparações entre controladores distintos.

Em relação ao DM, ele revela eficientemente como que a predição do modelo está em relação às saídas reais da planta. É importante salientar, entretanto, que em função de apenas diagnosticar o desempenho do modelo implementado, a utilização deste índice, apenas, acarreta certamente em equívoco. Não há nenhuma informação nesse índice que indique a qualidade da ação de controle determinada pelo MPC.

REFERÊNCIAS

ARAGÃO, M.E. Abordagem flexível, robusta e estruturada para o projeto de controladores PID multivariáveis. Dissertação de Mestrado, Departamento de Engenharia Química, UFRGS, 2006.

CAMACHO, E.F., BORDONS C. *Model Predictive Control*. 1 ed. Great Britain. Ed. Springer, 1999. 280p.

CUTLER, C.R., RAMAKER, B.L. *Dynamic Matrix Control – A Computer Control Algorithm*. In: 86th National Meeting of The American Institute of Chemical engineers, Apr. 1979.

HARRIS, T.J., BOUDREAU F., MACGREGOR J.F. *Performance assessment using of multivariable feedback controllers*. Automatica, v. 23, p. 1505–1518, 1996.

HUANG B., KADALI, R. *Dynamic modeling, predictive control and performance monitoring: a data driven subspace approach*. 1 ed. Ed. Springer, 2008, 240 p.

HUANG B., SHAH S.L. *Performance Assessment of Control Loops*. 1 ed. Ed. Springer, Berlin, 1999.

HROMKOVIC, J. *Algorithmics for hard problems: introduction to combinatorial optimization, randomization, approximation and heuristics*. 2 ed. Ed. Springer, 1998. 492 p.

KALMAN, R. E. *Contributions to the theory of optimal control*. Bulletin de la Societe Mathematique de Mexicana, v. 5, p. 102–119, 1960a.

KALMAN, R. E. *A new approach to linear filtering and prediction problems*. Transactions of ASME, Journal of Basic Engineering, v. 87, p. 35–45, 1960b.

KESAVAN, P., LEE, J. *Diagnostic tools for multivariable model-based control systems*. Industrial & Engineering Chemistry Research, v. 36, p. 2725–2738, 1997.

KO, B., EDGAR, T. *Performance assessment of multivariate feedback control systems*. Automatica, v. 37, p. 899–905, 2001.

MACIEJOWSKI, J.M. *Predictive Control with Constraints*. 1 ed. Ed. Prentice Hall, 2000, 331 p.

MARQUIS, P., BROUSTAIL, J. P. *SMOC, a bridge between state space and model predictive controllers: Application to the automation of a hydrotreating unit*. In: Proceedings of the 1998 IFAC workshop on model based process control, p. 37–43, Oxford, 1998.

MARTINS-SANCHEZ, J.M., RODELLAR, J. *Adaptive predictive control. From the concepts to plant optimization*. 1 ed. Ed. Prentice Hall PTR, 1996. 352 p.

PAIM, A.C. *Controle preditivo retroalimentado por estados estimados, aplicado a uma planta laboratorial*. Dissertação de Mestrado, Departamento de Engenharia Química, UFRGS, 2009.

PATWARDHAN, R.S., MCINTYRE B. *Monitoring, best practices maintain APC applications*. Oil and gas Journal, v. 30, i. 30, Aug. 2008.

PATWARDHAN R.S., SHAH S.L., QI K.Z. *Assessing the performance of model predictive controllers*. Canadian Journal of Chemical Engineering, v. 80, i. 5, p. 954-966, Oct. 2002.

PROPOI, A. I. *Use of LP methods for synthesizing sampled-data automatic systems*. Automation and Remote Control, v. 24, n. 7, p. 837-844, 1963.

RICHALET, J., RAULT, A., TESTUD, J. L., PAPON, J. *Model predictive heuristic control: applications to industrial processes*. Automatica, v. 14, p. 413–428, 1976.

RUEL, M., *Performance monitoring and supervision: an economic point of view*. In: ISA EXPO 2005 Technical Conference, Chicago, Oct. 2005.

TATJEWSKI, P. *Advanced control of industrial processes: structures and algorithms*. 1 ed. Great Britain. Ed. Springer, 2007. 332 p.

TRIERWEILER, J.O., ENGELL, S. *The robust performance number: a new tool for control structure design*. Computers & Chemical Engineering, v. 21, p. S409-S414, 1997.

YOUSFI, C., TOURNIER, R. *Steady-state optimization inside model predictive control*. In: Proceedings of ACC'91, Boston, MA, p. 1866-1870, 1991.

ZADEH, L. A., WHALEN, B. H. *On optimal control and linear programming*. IRE Transactions of Automation Control, v. 7, n. 4, p. 45-46, July. 1962.

ZHANG, Y., HENSON, M. *A performance measure for constrained model predictive controllers*. In: Proceedings of the 1999 European control conference, Karlsruhe, Germany, 1999.

ANEXOS

Anexo 1 – Matrizes S_u , S_d e S_x

$$S_u = \begin{bmatrix}
 C \cdot B_u & 0 & \dots & 0 & 0 \\
 \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_u & C \cdot B_u & 0 & \dots & 0 \\
 \sum_{j=1}^3 C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_u & \ddots & 0 & \vdots \\
 \vdots & \vdots & \ddots & C \cdot B_u & 0 \\
 \sum_{j=1}^{m-1} C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^{m-2} C \cdot A^{j-1} \cdot B_u & \dots & \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_u & C \cdot B_u \\
 \sum_{j=1}^m C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^{m-1} C \cdot A^{j-1} \cdot B_u & \dots & \sum_{j=1}^3 C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_u \\
 \vdots & \vdots & \ddots & \vdots & \vdots \\
 \sum_{j=1}^{p-1} C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^{p-2} C \cdot A^{j-1} \cdot B_u & \dots & \sum_{j=1}^{p-m+1} C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^{p-m} C \cdot A^{j-1} \cdot B_u \\
 \sum_{j=1}^p C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^{p-1} C \cdot A^{j-1} \cdot B_u & \dots & \sum_{j=1}^{p-m+2} C \cdot A^{j-1} \cdot B_u & \sum_{j=1}^{p-m+1} C \cdot A^{j-1} \cdot B_u
 \end{bmatrix}$$

$$S_d = \begin{bmatrix}
 C \cdot B_d & 0 & \dots & 0 & 0 \\
 \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_d & C \cdot B_d & 0 & \dots & 0 \\
 \sum_{j=1}^3 C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_d & \ddots & 0 & \vdots \\
 \vdots & \vdots & \ddots & C \cdot B_d & 0 \\
 \sum_{j=1}^{m-1} C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^{m-2} C \cdot A^{j-1} \cdot B_d & \dots & \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_d & C \cdot B_d \\
 \sum_{j=1}^m C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^{m-1} C \cdot A^{j-1} \cdot B_d & \dots & \sum_{j=1}^3 C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^2 C \cdot A^{j-1} \cdot B_d \\
 \vdots & \vdots & \ddots & \vdots & \vdots \\
 \sum_{j=1}^{p-1} C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^{p-2} C \cdot A^{j-1} \cdot B_d & \dots & \sum_{j=1}^{p-m+1} C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^{p-m} C \cdot A^{j-1} \cdot B_d \\
 \sum_{j=1}^p C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^{p-1} C \cdot A^{j-1} \cdot B_d & \dots & \sum_{j=1}^{p-m+2} C \cdot A^{j-1} \cdot B_d & \sum_{j=1}^{p-m+1} C \cdot A^{j-1} \cdot B_d
 \end{bmatrix}$$

$$Sx = \begin{bmatrix} C \cdot A \\ \sum_{j=1}^2 C \cdot A^j \\ \sum_{j=1}^3 C \cdot A^j \\ \vdots \\ \sum_{j=1}^m C \cdot A^j \\ \sum_{j=1}^{m+1} C \cdot A^j \\ \vdots \\ \sum_{j=1}^{p-1} C \cdot A^j \\ \sum_{j=1}^p C \cdot A^j \end{bmatrix}$$