

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO ACADÊMICO DE ELETRÔNICA
CURSO DE ESPECIALIZAÇÃO EM AUTOMAÇÃO INDUSTRIAL

LUIZ ROBERTO DE SOUZA JUNIOR

**CONTROLE PREDITIVO
APLICADO A UMA COLUNA DE DESTILAÇÃO BINÁRIA**

MONOGRAFIA DE ESPECIALIZAÇÃO

CURITIBA
2015

LUIZ ROBERTO DE SOUZA JUNIOR

**CONTROLE PREDITIVO
APLICADO A UMA COLUNA DE DESTILAÇÃO BINÁRIA**

Monografia de Especialização, apresentado ao Curso de Especialização em Automação Industrial, do Departamento Acadêmico de Eletrônica, da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para obtenção do título de Especialista.

Orientador: Prof. MSc. Anderson Levati Amoroso.

CURITIBA
2015

TERMO DE APROVAÇÃO

LUIZ ROBERTO DE SOUZA JUNIOR

CONTROLE PREDITIVO APLICADO A UMA COLUNA DE DESTILAÇÃO BINÁRIA

Este trabalho de conclusão de curso foi apresentado no dia 14 de agosto de 2015, como requisito parcial para obtenção do título de Especialista em Automação Industrial, outorgado pela Universidade Tecnológica Federal do Paraná. O aluno Luiz Roberto de Souza Junior foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Kleber Kendy Horikawa Nabas
Coordenador de Curso
Departamento Acadêmico de Eletrônica

BANCA EXAMINADORA

Prof. Dr. Kleber Kendy Horikawa Nabas
UTFPR

Prof. Dr. Sérgio Leandro Stebel
UTFPR

Prof. MSc. Anderson Levati Amoroso
Orientador - UTFPR

À Gécica, minha esposa, à minha irmã Gisele e à sobrinha Rafaela.
Ao meu pai Luiz e em especial a minha mãe Lene (*in memoriam*).
Por conferirem a mim, alegria, amor, paz e motivação nessa existência.

AGRADECIMENTOS

A Deus, pela vida, benção e proteção, sempre.

Aos professores do curso de Especialização em Automação Industrial da Universidade Tecnológica Federal do Paraná, em especial ao professor Anderson Levati Amoroso pelas orientações, incentivo, correções e confiança, além dos professores Kleber Kendy Horikawa Nabas e Sérgio Leandro Stebel por participarem da banca examinadora, sobretudo pelas sugestões e correções que fizeram.

Aos amigos de curso com os quais trocamos muitas experiências, tendo eles chegado ou não até o fim desta empreitada.

Agradeço ao meu querido pai Luiz, por quem tenho uma admiração sem fim e um respeito inestimável, pelo carinho, amor, além de estar sempre ao meu lado orientando e incentivando a superar as dificuldades naturais da vida.

À minha querida mãe Lene, pelo amor, paciência, dedicação, incentivo. Tenho certeza que na morada em que se encontras, está vibrando por todos nós e se alegrando com os pequenos passos que temos dado em vida.

À minha querida irmã Gisele, pelo amor, torcida, incentivo e à minha linda sobrinha Rafaela, um sopro de esperança na vida da nossa família.

Agradeço em especial a minha amada mulher Géssica, por tudo que fez e faz para o nosso relacionamento. São muitos anos de cumplicidade, respeito e incentivo. Obrigado pela paciência e por me apoiar nessa longa, mas satisfatória empreitada que é estudar.

Por fim, à Universidade Tecnológica Federal do Paraná por oferecer um serviço de extrema qualidade, por cultivar no seu quadro professores altamente qualificados e identificados com a arte de ensinar.

“Ninguém ignora tudo. Ninguém sabe tudo. Todos nós sabemos alguma coisa. Todos nós ignoramos alguma coisa. Por isso aprendemos sempre”

Paulo Freire

RESUMO

SOUZA JUNIOR, Luiz Roberto. **Controle preditivo aplicado a uma coluna de destilação binária**. 2015. 51 f. Monografia (Curso de Especialização em Automação Industrial), Departamento Acadêmico de Eletrônica, Universidade Tecnológica Federal do Paraná. Curitiba, 2015.

As tecnologias de controle avançado, bem como as de otimização de processos têm sido extremamente importantes para a rentabilidade, eficiência, segurança e sustentabilidade das plantas industriais. Nesse contexto, o controle preditivo, o *Model Predictive Control* (MPC), é uma importante opção de tecnologia muito eficaz para lidar com as exigências cada vez mais crescentes, sobretudo porque é capaz de ser integrada facilmente com estratégias de otimização. Trata-se de uma técnica importante de ser utilizada em unidades com dinâmica complexa, com tempos mortos elevados e respostas inversas. No entanto, quanto mais simples for o algoritmo de controle utilizado que sirva para obter os benefícios desejados, melhor, porque mais fácil será a manutenção destas ferramentas em operação. Assim sendo, esta monografia apresenta um projeto de controle preditivo aplicado a uma coluna de destilação binária, utilizando para isso, o software Matlab®, em especial, o seu pacote *Model Predictive Control Toolbox™*. Os resultados obtidos são descritos ao longo do texto, destacando a facilidade de implementação, robustez e poder dessas ferramentas.

Palavras-chave: Controle Preditivo. Destilação Binária. Matlab®.

ABSTRACT

SOUZA JUNIOR, Luiz Roberto. **Model Predictive Control applied to a binary distillation column.** 2015. 51 f. Monografia (Curso de Especialização em Automação Industrial), Departamento Acadêmico de Eletrônica, Universidade Tecnológica Federal do Paraná. Curitiba, 2015.

The advanced control technologies, as well as process optimization have been extremely important for the profitability, efficiency, safety and sustainability of industrial plants. In this context, the model predictive control, MPC, is an important option of technology very effective to deal with ever-increasing requirements, mainly because it can be easily integrated with optimization strategies. That is about an interesting technique to be used in units with complex dynamics, high dead times and reverse responses. However, the simpler the control algorithm used that serve for the desired benefits, the better, because the easier the maintenance of these tools in operation. Therefore, this monograph presents a model predictive control design applied to a binary distillation column, making use of the Matlab® software, in particular its Model Predictive Control Toolbox™ package. The results obtained are described throughout the text, highlighting the ease of implementation, robustness, and power of these tools.

Keywords: Predictive Control. Binary distillation. Matlab.

LISTA DE FIGURAS

Figura 1 - Esquema Coluna de Destilação	10
Figura 2 - Processo SISO.....	15
Figura 3 - Processo MIMO	15
Figura 4 - Diagrama de blocos sistema 2x2	16
Figura 5 - Sistema de controle com desacopladores	17
Figura 6 - Diagrama de blocos de um sistema de controle preditivo.....	19
Figura 7 - Conceito básico para um MPC	20
Figura 8 - Resposta ao degrau unitário na variável manipulada (vazão de refluxo)..	27
Figura 9 - Resposta ao degrau unitária na variável manipulada S (Vazão de vapor no refervedor).....	28
Figura 10 - Controle servo da coluna com $P = 8$ e $M = 8$	29
Figura 11 - Controle servo da coluna com $P = 8$ e $M = 7$	29
Figura 12 - Controle servo da coluna com $P = 8$ e $M = 3$	30
Figura 13 - Controle servo da coluna com $P = 8$ e $M = 1$	30
Figura 14 - Controle servo da coluna com $P = 8$ e $M = 8$, minimizando o ringing ponderandoas entradas	31
Figura 15 - Controle servo da coluna com $P = 8$ e usando o recurso blocking com $M = [1,2,3]$	32
Figura 16 - Controle Regulatório da coluna com $P = 5$ e $M = 5$	33
Figura 17 - Controle Regulatório da coluna com $P = 5$ e $L = 5$ e com ação antecipatória.....	33

LISTA DE TABELAS

Tabela 1 - Variáveis da coluna Metanol/Água	25
Tabela 2 - Parâmetros do Controlador	26

SUMÁRIO

1 INTRODUÇÃO.....	4
1.1 TEMA.....	5
1.2 DELIMITAÇÃO DO ESTUDO	5
1.3 OBJETIVOS.....	6
1.3.1 Objetivo Geral.....	6
1.3.2 Objetivos Específicos	6
1.4 JUSTIFICATIVA.....	6
2 REVISÃO BIBLIOGRÁFICA	8
2.1 Modelagem Matemática na Engenharia Química	8
2.1.1 Modelo Matemático de uma coluna de destilação binária ideal.....	10
2.2 Controle de Processos em Sistemas Multivariáveis	14
2.2.1 Introdução ao Controle Preditivo	18
3 APLICAÇÃO DO CONTROLE PREDITIVO MULTIVARIÁVEL.....	25
4 RESULTADOS E DISCUSSÕES.....	27
5 Conclusão.....	34
6 Sugestão para trabalhos futuros.....	36
REFERÊNCIAS	37
ANEXOS.....	38

1 INTRODUÇÃO

A indústria de processos químicos está envolvida na produção de uma ampla variedade de produtos que levam conforto à vida das pessoas, bem como rendimento para as companhias e seus *stackholders*. Em geral, processos químicos são complexos e frequentemente envolvem substâncias com alta reatividade, toxicidade e corrosividade, além de operar em altas temperaturas e pressões, características que podem levar a uma variedade de consequências potencialmente sérias, incluindo explosões, danos ambientais e ameaças à saúde das pessoas (TURTON et al., 2009, p. 30).

A concepção de um processo químico é um conjunto numeroso e diversificado de atividades desenvolvidas por uma equipe de engenheiros químicos, que surge a partir da decisão de se produzir um determinado produto em escala industrial cujo resultado é um plano bem definido para a construção e a operação da instalação desejada. Simplificadamente ficam definidos no decorrer do projeto: a rota tecnológica para a obtenção do produto; o fluxograma do processo (definição dos equipamentos, seu sequenciamento e das correntes), as dimensões dos equipamentos, bem como as condições das correntes e as condições operacionais, estabelecidas segundo critérios econômicos, ambientais e de segurança. Assim, para atender as definições acima, o projeto passa, em geral, a ser desdobrado em problemas específicos de reatores, processos de separação, mecânica dos fluidos, transferência de calor e massa, termodinâmica, cinética, controle de processo, avaliação econômica e segurança (PERLINGEIRO, 2005, p. 2).

Deste modo, uma planta química deve operar a fim de satisfazer várias exigências estabelecidas pelo projeto e pelas condições técnicas, econômicas e sociais, quando submetida a influências externas (perturbações). Logo, existe a necessidade do seu monitoramento contínuo, bem como de intervenções externas (controle) para garantir os objetivos operacionais que é feito através de uma topologia racional de equipamentos (dispositivos de medição, válvulas, controladores, computadores) e por intervenção humana (supervisores, operadores), que juntos constituem o sistema de controle (KWONG, 2012a, p. 9).

Por fim, no escopo do controle de processos há uma divisão simplificada entre controle *feedback* clássico PID e controle avançado que abarca técnicas de controle baseado em modelo como o preditivo, bem como os chamados livres de modelo. Além disso, há uma distinção entre os sistemas que podem possuir desde uma única variável, até os que possuem de duas a dezenas de variáveis a serem controladas, são os sistemas monovariáveis, conhecidos como *Single-Input-Single-Output* (SISO) e os multivariáveis ou *Multiple-Input-Multiple-Output* (MIMO), os últimos tipos de sistema são bem mais complexos de controlar, sobretudo pela interação que há entre as variáveis manipuladas e controladas do processo.

É aí que o controle avançado desempenha papel primordial, tratar de processos multivariáveis com eficiência, bem como de sistemas com dinâmica complexas.

1.1 TEMA

Escolheu-se uma operação unitária, especificamente uma coluna de destilação binária, utilizada para a separação de uma mistura de metanol e água, como caso da aplicação de controle preditivo multivariável com abordagem no escopo do controle avançado de processo.

1.2 DELIMITAÇÃO DO ESTUDO

Dentre as várias técnicas de controle avançado, escolheu-se trabalhar com o controle preditivo multivariável que é, em específico, uma técnica baseada em modelo bastante difundida nas indústrias de processo químico.

1.3 OBJETIVOS

Nesta seção são apresentados os objetivos geral e específicos do trabalho, relativos ao controle de uma coluna de destilação binária.

1.3.1 Objetivo Geral

Avaliar a utilização do controle de processo avançado em uma coluna de destilação binária de uma mistura de metanol e água. Sistema amplamente utilizado para estudos de técnicas de controle.

1.3.2 Objetivos Específicos

Etapas a serem realizadas para atingir o objetivo geral:

- a. Apresentar o modelo matemático da coluna de destilação;
- b. Realizar o controle preditivo baseado em modelo; tudo auxiliado pelo software Matlab®, em específico utilizando a caixa de ferramentas denominada *Model Predictive Control Toolbox™*.
- c. Avaliar o desempenho do sistema de controle.

1.4 JUSTIFICATIVA

As indústrias de processo são confrontadas com um ambiente cada vez mais competitivo e em constante mudança, seja nas condições de mercado, como nas regulamentações governamentais, mantendo a exigência de aumentar a produtividade e rentabilidade. Nessa perspectiva, o controle de processos tem um papel fundamental e o controle preditivo ainda mais, sobretudo pela sua característica

de ser utilizado juntamente com uma camada de otimização que permite que os processos sejam operados de forma mais eficiente. No entanto, uma das principais desvantagens desse tipo de sistema é que eles, em geral, não são familiares aos técnicos e engenheiros que operam as plantas. Assim, toda referência com o propósito de explicar um pouco mais do assunto, já tem por si só, a sua contribuição.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo está dividido em duas seções. Na primeira é apresentada a modelagem matemática na Engenharia Química e na sequência é dado enfoque ao modelo matemático de uma coluna de destilação binária ideal cujo controle é objeto do presente estudo. Por fim, na segunda seção é abordado o controle preditivo multivariável de processos químicos.

2.1 Modelagem Matemática na Engenharia Química

Os modelos são, segundo Ingham (2007, p. 1), parte integral de qualquer tipo de atividade humana e variam muito, podendo ser, por exemplo, de natureza qualitativa, quantitativa, representados por protótipos, comportamentos e muito mais. No entanto, para fins técnicos e científicos destacam-se os modelos expressos em termos matemáticos. Deste modo, para Aguirre (2000, p. 37), a modelagem matemática é a área do conhecimento que estuda maneiras de desenvolver e utilizar modelos matemáticos que representam sistemas reais. Tais modelos, em geral, são obtidos de várias maneiras e técnicas, destacando a modelagem fenomenológica, também conhecida como modelagem caixa branca, conceitual ou pela física. Já a modelagem empírica ou dita caixa preta que tem como característica o pouco ou nenhum conhecimento prévio do sistema, recebendo o nome, por vezes, de identificação de sistemas.

A identificação de sistemas é um procedimento alternativo cujo desenvolvimento é estimulado devida a dificuldade de tempo e conhecimento suficientes para desenvolver modelos a partir das equações que regem a física do processo. Segundo Campos, Gomes e Perez (2013, p. 120), tal identificação consiste em obter dados adequados da planta industrial através de testes necessários para se ter bons dados e, conseqüentemente, bons modelos.

Uma forma de modelo muito utilizada são as Funções de Transferência que representam o comportamento dinâmico de um par entrada-saída do sistema, isto é,

exibem como uma dada entrada é dinamicamente “transferida” para a saída. É uma ferramenta utilizada para sistemas lineares e pode ser obtida aplicando-se a transformada de Laplace à equação diferencial que descreve o sistema, ou a partir de dados produzidos por ele, utilizando, portanto, processos de identificação já mencionados (AGUIRRE, 2000, p. 76-77).

É importante pontuar que o modelo desenvolvido para um determinado sistema, de acordo com Aguirre (2000, p. 38-39), é apenas uma representação aproximada. Assim sendo, não há o modelo do sistema, mas sim uma família de modelos com características e desempenhos variados. Além disso, o modelo é uma aproximação de apenas algumas características do sistema real e obter um modelo que represente o sistema com todas as suas nuances é por vezes, um alvo inatingível.

Na Engenharia Química a modelagem fenomenológica de um processo químico requer, segundo Kwong (2012a, p. 35), o uso de princípios básicos da área, como Termodinâmica, Cinética, Fenômenos de Transporte, etc., de tal modo que o modelo matemático do sistema é útil pelos seguintes motivos: melhor entendimento do processo, treinamento de operadores, desenho de estratégia de controle de um novo processo, escolha dos ajustes do controlador, desenho da lei de controle, otimização das condições de operação do processo, entre outros.

Para a maioria dos sistemas de interesse ao engenheiro químico, há apenas três quantidades fundamentais: massa, energia e momento. Geralmente, essas variáveis não podem ser medidas direta e convenientemente, deste modo, outras variáveis, mais facilmente mensuráveis, são convenientemente selecionadas e agrupadas a fim de determinar os valores das variáveis fundamentais. Portanto, massa, momento e energia podem ser caracterizadas por densidade, concentração, temperatura, pressão, vazão que são variáveis chamadas de estado e seus valores definem o estado de um sistema de processamento (KWONG, 2012a, p.35).

Os trabalhos de Kwong (2012a, p. 36-47), Seborg et al. (2010, p. 14-28), Luyben (1996, p. 17-38) e Bequette (1998, p. 17-33), exemplificam o que foi exposto acima ao trazerem modelos matemáticos fundamentados no princípio de conservação das quantidades fundamentais (massa, energia e momento), além de seus elementos adicionais.

2.1.1 Modelo Matemático de uma coluna de destilação binária ideal

Para desenvolver o estudo de caso proposto nesse trabalho, escolheu-se o modelo dinâmico proposto por Wood e Berry (1973, p. 1717), obtido experimentalmente. No entanto, optou-se também por apresentar o modelo fenomenológico de uma coluna de destilação binária ideal, exemplificada em Kwong (2012a, p. 47) e que serve para explicar o funcionamento básico do sistema de separação.

Dada a coluna de destilação da Figura 1 que separa uma mistura dos componentes A e B em duas correntes de produto, tem-se que a alimentação, composta de líquido saturado, ou seja, no seu ponto de bolha, é efetuada no prato f com uma vazão F_f e fração molar de A c_f . A corrente de vapor no topo é resfriada e completamente condensada seguindo para o tambor de refluxo cujo conteúdo de líquido é dado por M_{RD} e é bombeado parcialmente para compor a corrente de refluxo da coluna, entrando no prato N com uma vazão F_R e também retirado como destilado com uma vazão F_D e fração molar de A x_D . O conteúdo de líquido no prato i é M_i e o de vapor considerado desprezível. O produto de fundo é retirado pela base da coluna com uma vazão F_B e composição x_B , além dele, outra corrente de líquido com vazão molar V , também é retirada pela base da coluna, sendo aquecida no refeedor e retornando à base na forma de vapor M_i . O volume de líquido na base da coluna é estabelecido como M_B , tendo composição x_B .

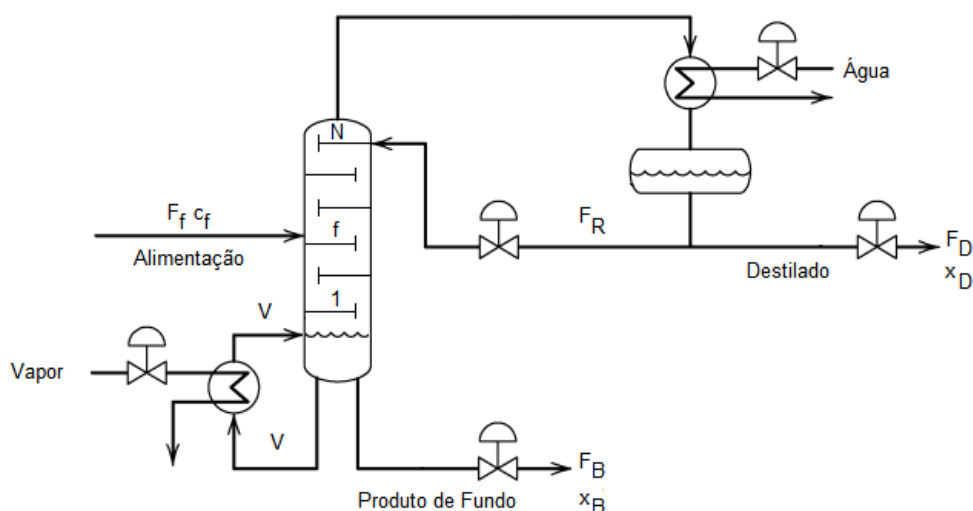


Figura 1 - Esquema Coluna de Destilação
Fonte: O autor

Para facilitar o processo de se obter um modelo fenomenológico em questão, algumas suposições são assumidas:

1. Conteúdo de vapor em cada prato é desprezível.
2. Os calores de vaporização de A e B são aproximadamente iguais. Isto significa que quando um mol de vapor se condensa, ele vaporiza um mol de líquido.
3. Coluna adiabática.
4. Volatilidade relativa α dos dois componentes permanece constante ao longo da coluna.
5. Eficiência dos pratos é de 100% (isto é, o vapor que deixa cada prato está em equilíbrio com o líquido).
6. As dinâmicas do condensador e do refeedor são desprezíveis.
7. A vazão molar de líquido em cada prato está relacionada ao conteúdo de líquido pela fórmula de Francis (1):

$$L_i = f(M_i) \quad (1)$$

Uma expressão dessa fórmula é (2):

$$L = 3.33lh^{3/2} \quad (2)$$

Onde:

L é dado em ft^3/s ;

l é o comprimento do vertedouro em ft;

h é a altura de líquido acima do vertedouro em ft;

Das suposições 1, 2 e 3, tem-se que $V = V_1 = V_2 = \dots = V_N$, portanto, não há necessidade de balanço de energia nos pratos.

Da suposição 5, pode-se, então, equação (3), chegar à seguinte relação entre y_i (fração molar de A no vapor) e x_i (fração molar de A no líquido):

$$y_i = \frac{\alpha x_i}{1 + (\alpha - 1)x_i} \quad (3)$$

Em que α é a volatilidade relativa entre A e B e é obtida a partir das equações (4) e (5).

$$K_i = \frac{y_i}{x_i} \quad (4)$$

$$\alpha_{ij} = \frac{K_i}{K_j} \quad (5)$$

Outra etapa importante na modelagem da coluna são os balanços de massa. As equações 6 a 8, tratam da conservação de massa no prato de alimentação, representado por f na figura 1, sendo (6) e (7) equações de balanço global e (8) equação de balanço do componente A.

$$\frac{d(M_f)}{dt} = F_f + L_{f+1} + V_{f-1} - L_f - V_f \quad (6)$$

$$\frac{d(M_f)}{dt} = F_f + L_{f+1} - L_f \quad (7)$$

$$\frac{d(M_f x_f)}{dt} = F_f c_f + L_{f+1} x_{f+1} + V_{f-1} y - L_f x_f - V_f y \quad (8)$$

As equações (9) a (11), representam o balanço de massa no prato de topo N. Sendo 11 equação de balanço do componente A. Como a vazão de vapor é constante, $V_{N-1} = V_N$. Então,

$$\frac{d(M_N)}{dt} = F_R + V_{N-1} - L_N - V_N \quad (9)$$

$$\frac{d(M_N)}{dt} = F_R - L_N \quad (10)$$

$$\frac{d(M_N x_N)}{dt} = F_R x_D + V_{N-1} y_{N-1} - L_N x_N - V_N y_N \quad (11)$$

Para o prato de fundo 1, o mesmo procedimento é seguido. Observando que $V = V_1$, tem-se que a equação (12) torna-se (13) e a equação (14) é do balanço de massa do componente A.

$$\frac{d(M_1)}{dt} = L_2 - L_1 + V - V_1 \quad (12)$$

$$\frac{d(M_1)}{dt} = L_2 - L_1 \quad (13)$$

$$\frac{d(M_1x_1)}{dt} = L_2x_2 + Vy_B - L_1x_1 - V_1y_1 \quad (14)$$

Para os demais pratos i ($i = 2, \dots, N-1, i \neq f$), tem-se as equações (15), (16) e (17):

$$\frac{d(M_i)}{dt} = L_{i+1} - L_i + V_{i-1} - V_i \quad (15)$$

$$\frac{d(M_i)}{dt} = L_{i+1} - L_i \quad (16)$$

$$\frac{d(M_ix_i)}{dt} = L_{i+1}x_{i+1} + V_{i-1}y_{i-1} - L_ix_i - V_iy_i \quad (17)$$

Por fim, o balanço de massa também é realizado no acumulador (tambor de refluxo) e na base da coluna, equações (18), (19) e (20) a (23), respectivamente.

$$\frac{d(M_{RD})}{dt} = V_N - F_R - F_D \quad (18)$$

$$\frac{d(M_{RD}x_D)}{dt} = V_Ny_N - (F_R + F_D)x_D \quad (19)$$

$$\frac{d(M_B)}{dt} = L_1 - V - F_B - V + V \quad (20)$$

$$\frac{d(M_B)}{dt} = L_1 - V - F_B \quad (21)$$

$$\frac{d(M_B x_B)}{dt} = L_1 x_1 - V y_B - F_B x_B - V x_B + V x_B \quad (22)$$

$$\frac{d(M_B x_B)}{dt} = L_1 x_1 - V y_B - F_B x_B \quad (23)$$

Vale destacar que toda as equações de balanço são equações de estado cujas variáveis de estado são: $M_1, M_2, \dots, M_N, M_{RD}, M_B, x_1, x_2, \dots, x_N, x_D$ e x_B .

Outra equação importante na modelagem de uma coluna de destilação binária é a que estabelece o equilíbrio líquido-vapor em cada um dos estágios de separação. Assim, com a equação (24) é possível determinar a fração de vapor e líquido.

$$y_i = \frac{\alpha x_i}{1 + (\alpha - 1)x_i} \quad i = B, 1, \dots, f, \dots, N \quad (24)$$

Conforme comentado na seção 2.1, a modelagem fenomenológica é, na maioria das vezes, um processo muito dispendioso. Pode-se observar na modelagem da coluna de destilação binária que um sistema de equações diferenciais deve ser solucionado com o método numérico conveniente, no entanto, a principal questão é que no geral, esse tipo de modelagem envolve uma série de aproximações, ou seja, uma série de suposições utilizadas para facilitar o desenvolvimento do modelo. Fica claro que para sistemas muito complexos, com muitas variáveis, tal procedimento não é comumente realizado. Assim, é pelos motivos citados que a identificação de sistemas é a forma mais difundida na indústria.

2.2 Controle de Processos em Sistemas Multivariáveis

Segundo Luyben (1990, p. 535), a área do controle de processos que mais drasticamente mudou nas últimas décadas foi o controle multivariável. Mudança que foi impulsionada pelo aumento, cada vez mais frequente, de processos altamente

complexos, com variáveis com grande interação entre si, projetados para serem energeticamente cada vez mais eficientes.

A teoria de controle aborda, no geral, dois tipos de processos, os denominados *Single-Input-Single-Output* (SISO), Figura 2, envolvendo problemas que possuem apenas uma entrada, ou seja, a variável manipulada e uma saída, a variável controlada, e os processos *Multiple-Input-Multiple-Output* (MIMO), Figura 3, que possuem mais de uma variável controlada e mais de uma manipulada, sendo os tipos de problema mais comumente encontrados na prática, os chamados sistemas multivariáveis (SEBORG; MELLICHAMP, 2010, p. 341).

De modo geral, a teoria clássica de controle de processos, de acordo com Wang et al. (2008, p. 1-3), é apropriada para lidar efetivamente com os processos SISO, tornando-se menos eficiente para lidar com os processos multivariáveis. No entanto, nas últimas décadas, muitas tentativas foram feitas para estender a teoria de controle clássico para os processos com mais de uma variável envolvida. Deste modo, há uma diversidade considerável de técnicas disponíveis, como por exemplo, a que usa desacopladores.




Figura 2 - Processo SISO

Fonte: Adaptado de Seborg e Mellichamp (2010, p. 343)




Figura 3 - Processo MIMO

Fonte: Adaptado de Seborg e Mellichamp (2010, p. 343)

Os problemas de controle MIMO são inerentemente mais complexos que os SISO, segundo Seborg e Mellichamp (2010, p. 343), uma vez que há, em geral, interações entre as variáveis controladas e manipuladas, a alteração numa dada variável manipulada, por exemplo u_1 , afeta todas as variáveis controladas, y_1, y_2, \dots, y_n . De tal modo que para num sistema com n variáveis controladas e n manipuladas, há $n!$ possibilidades de interação entre entrada e saída. Por exemplo, uma coluna de destilação com 5 variáveis manipuladas e 5 variáveis controladas, possui $5! = 120$ maneiras diferentes de pareamento entre variáveis de entrada e saída.

Para um sistema 2x2, ou seja, com duas variáveis manipuladas e duas controladas, dois esquemas simplificados de controle podem ser configurados (Figura 4). No esquema (a), a variável Y_1 é controlada manipulando-se U_1 e Y_2, U_2 , configuração denominada 1-1/2-2. Em contrapartida em (b), tem-se os pares Y_1 com U_2 e Y_2 com U_1 , configuração denominada 1-2/2-1.

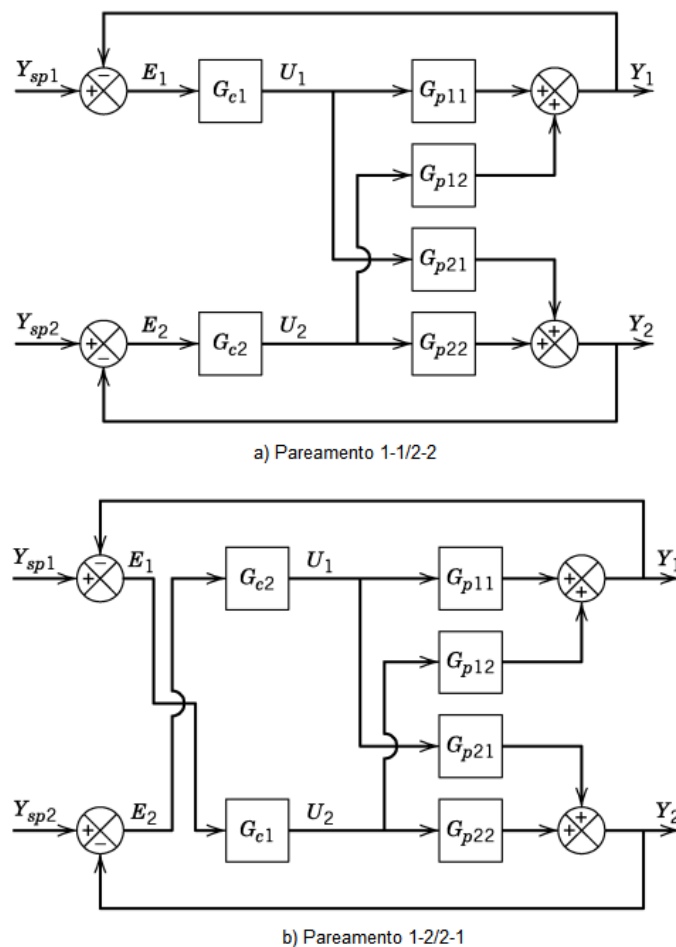


Figura 4 - Diagrama de blocos sistema 2x2
Fonte: Seborg e Mellichamp (2010, p. 344)

O problema mais importante que envolve os processos MIMO é a interação entre as malhas de controle. A Figura 4 indica que interação entre malhas de controle podem acarretar em comportamento indesejável individualmente, ou seja, analisando o esquema (a), por exemplo, se Y_1 é de alguma forma perturbado, o controlador para o *loop 1* (G_{c1}) ajusta U_1 para forçar que Y_1 volte ao *setpoint*. No entanto, U_1 afeta Y_2 via G_{p21} . Da mesma forma, o controlador para o *loop 2* (G_{c2}) ajusta U_2 para forçar que Y_2 volte ao *setpoint*, caso ocorra alguma perturbação. E por consequência, via G_{p12} , U_2 afeta Y_1 .

Para diminuir a interação, uma das primeiras abordagens, segundo Seborg e Mellichamp (2010, p. 358), foi o uso de blocos desacopladores, como T_{21} e T_{12} apresentados na Figura 5, que permitiram com que mudanças no *setpoint* de uma variável controlada afetasse pouco ou nada uma outra variável também controlada. Na prática, estes benefícios não podem ser plenamente realizados devido à vários fatores, como por exemplo, modelos de processos imperfeitos.

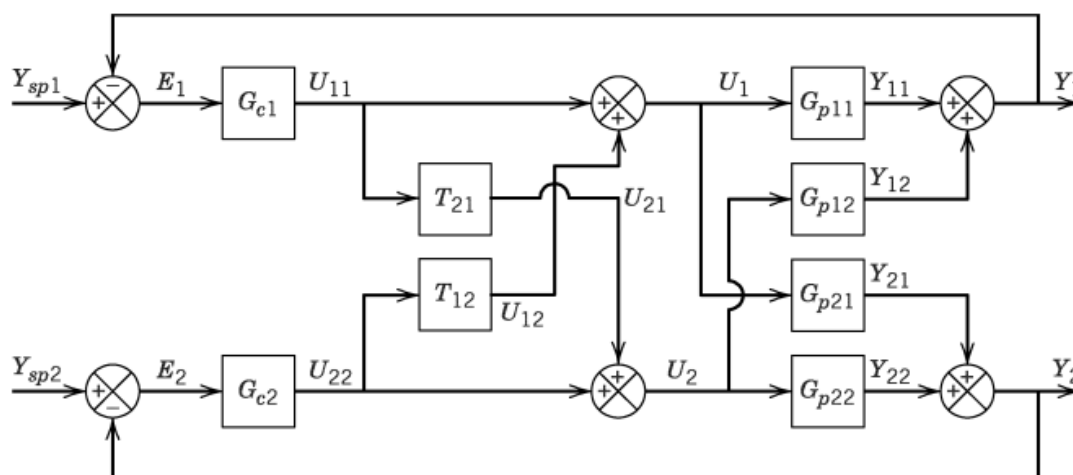


Figura 5 - Sistema de controle com desacopladores
Fonte: Seborg e Mellichamp (2010, p. 358)

Em síntese, se a principal dificuldade dos problemas de controle MIMO é o alto grau de acoplamento das malhas e não puder ser superada pela teoria de controle clássica, uma das alternativas é empregar estratégias de controle multivariável, como por exemplo, o controle preditivo.

2.2.1 Introdução ao Controle Preditivo

De modo diferente do controle *feedback* clássico PID, onde o controlador atua sobre um dado erro para calcular as ações de controle, Kwong (2012b, p. 11) traz que o controle preditivo, ou *Model Predictive Control* (MPC), utiliza diretamente um modelo do processo para calcular essas ações. Trata-se de um método especialmente adequado para problemas difíceis de controle, sobretudo em processos MIMO onde existem interações significativas entre as entradas manipuladas e as saídas controladas. Além disso, o MPC, diferente de outras estratégias de controle baseadas em modelo, trata com muita facilidade restrições de desigualdade nas variáveis de entrada e saída, e por isso é muito utilizado associado, segundo Campos, Gomes e Perez (2013, p. 220), à uma camada de otimização, de tal forma que é possível operar a maioria das plantas industriais no seu ponto ótimo através do ajuste dinâmico das variáveis manipuladas, mesmo com as perturbações sofridas pela planta.

Um diagrama de blocos de um sistema de controle preditivo é mostrado na Figura 6. Observa-se que um modelo de processo é utilizado para prever os valores atuais das variáveis de saída. O resíduo que é a diferença entre as saídas previstas e as do processo, serve de sinal *feedback* para o bloco de predição cujo sinal de saída é usado para dois tipos de cálculos MPC que são executados em cada instante de amostragem: cálculo de *setpoints* e cálculo de controle. Além disso, restrições de desigualdade nas variáveis de entrada e de saída podem ser incluídos nesses cálculos, sem maiores dificuldades. Os *setpoints* para os cálculos de controle são determinados, em geral, a partir de uma otimização econômica do processo que é baseada no seu modelo em estado-estacionário, podendo ser, por exemplo, um modelo linear. Em geral, as funções objetivo, nesses casos, envolvem maximização de lucro, minimização de custos ou, por exemplo, maximização de uma determinada taxa de produção (SEBORG; MELLICHAMP, 2010, p. 387).

Resumindo, os cálculos MPC são baseados em medidas momentâneas e previsões de valores futuro das saídas, tendo como objetivo determinar uma sequência de movimentos de controle, ou seja, através de mudanças na variável manipulada (entrada), de modo que a resposta prevista se mova para o *setpoint* de uma maneira otimizada.

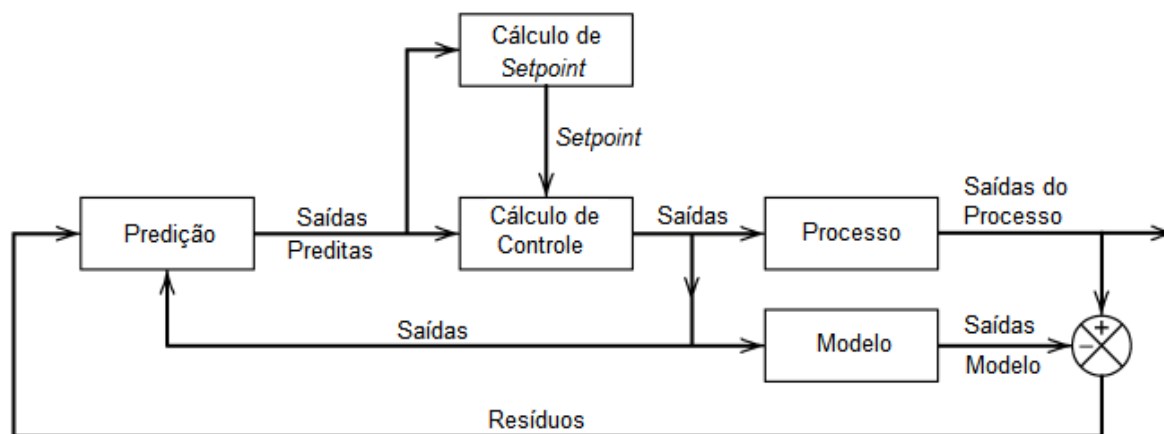


Figura 6 - Diagrama de blocos de um sistema de controle preditivo
 Fonte: Seborg e Mellichamp (2010, p. 387)

Segundo os trabalhos de Seborg e Mellichamp (2010, p. 387), bem como, de Campos, Gomes e Perez (2013, p. 174), algumas etapas podem ser observadas no algoritmo de um controlador preditivo multivariável (Figura 7).

1. As variáveis do processo (manipuladas, perturbações e controladas) são lidas no instante atual “k”;
2. Por meio de um modelo implementado no controlador, o algoritmo realiza a predição futura do comportamento da saída do processo, levando em consideração as entradas de controle atuais e futuras. Esta predição considera certo horizonte de “P” intervalos futuros. Deste modo, a estratégia MPC calcula um conjunto de M valores de entrada, dada por $\{u(k+i-1)\}$, sendo $i = \{1, 2, \dots, M\}$. A entrada é mantida constante depois dos M movimentos de controle. As entradas são calculadas de forma que um conjunto de P saídas preditas, $\hat{y}(k+i)$, $i = \{1, 2, \dots, P\}$ atinjam o *setpoint* de maneira ótima;
3. A predição deve ser corrigida a cada intervalo de amostragem “k”, em função das medições disponíveis das variáveis do processo, que permitem inferir o erro de predição futuro com base no cometido no passado;
4. Em cada interação, o controlador calcula uma sequência de ações de controle. O tamanho desta sequência é definido pelo horizonte de controle “M”. Esta sequência calculada minimiza certa função objetivo específica do problema em questão;

5. Após resolver o problema de otimização descrito acima, o controlador implementa na planta somente a primeira ação de controle $\Delta u(k)$ em meio a sequência de ações calculadas, que vão do intervalo de instante atual até o intervalo correspondente ao horizonte de controle “M” ajustado no controlador;
6. Depois da atuação nas variáveis manipuladas do processo, o controlador espera o próximo intervalo de tempo “k+1” para executar outra vez todas as ações descritas anteriormente.

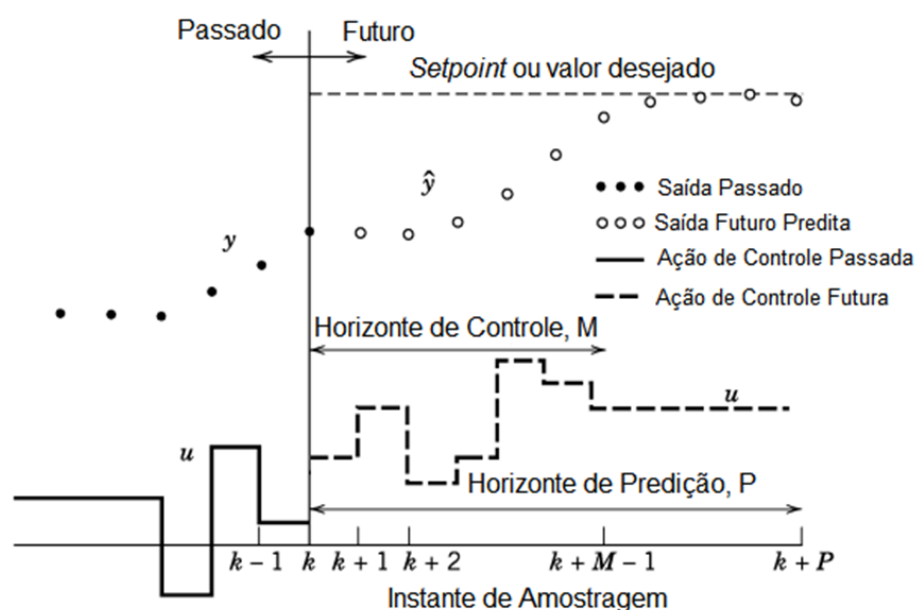


Figura 7 - Conceito básico para um MPC
 Fonte: Seborg e Mellichamp (2010, p. 388)

Resumindo, no instante “k”, aplica-se, por exemplo, um degrau no *setpoint* da variável controlada y e em função do erro existente, o controlador calcula as “M” ações de controle que minimizam o somatório quadrático dos erros preditos até o horizonte de predição “P” da variável controlada. Depois de calcular esta sequência de ações ótimas, apenas a primeira ação $u(k)$ é aplicada ao processo e é mantida constante até o próximo instante “k + 1”. O intervalo de amostragem ou execução do Controle Preditivo Multivariável é um parâmetro definido durante o projeto do controlador e depende das constantes de tempo dominantes do processo.

No instante “k + 1”, obtém-se a leitura da variável controlada $y(k + 1)$ através da instrumentação de campo. A diferença existente entre o valor da predição no

instante anterior e o obtido do sensor da planta, pode ser devido, por exemplo, a um erro de modelagem. Também pode ser justificada pela existência de perturbações sobre a variável controlada. Após a correção da predição, novas “M” ações de controle são calculadas visando, por exemplo, minimizar a soma dos erros ao quadrado entre a predição e o *setpoint*.

Por fim, antes da apresentação do estudo de caso que faz parte do objetivo do trabalho é comentar sobre o processo de sintonia do controlador preditivo, bem como pontuar as principais vantagens e desvantagem do controle que até aqui foi mostrado.

Segundo Campos, Gomes e Perez (2013, p. 244), o processo de sintonia do controlador preditivo é um trabalho amplo e recomenda-se incluir os seguintes passos:

1. Obtenção e validação dos modelos: para esta classe de controladores baseados em modelos, a qualidade desta informação pode ser considerada o principal “parâmetro” de sintonia;
2. Pré-sintonia dos parâmetros do controlador: utilizam-se, no geral, estratégias heurísticas.
3. Simulações dinâmicas do controlador, avaliando o desempenho da pré-sintonia para diversos cenários (perturbações esperadas, ruídos, comportamento com diferentes restrições ativas nas manipuladas e controladas, inclusão de erros de modelagem para avaliar a robustez, etc.). A simulação é igualmente muito importante para detectar erros na configuração do controlador, bem como minimizar o tempo de ajustes nas sintonias do controlador durante o início da operação na planta;
4. Implementação do controlador no processo em questão e avaliação do desempenho (primeiro em malha aberta com validação das ações propostas pelo controlador, uma vez que a predição da resposta futura do processo possui uma parte que depende das ações de controle futuras e outra que é função das ações de controle passadas e é conhecida como predição em malha aberta e posteriormente atuando na planta).
5. Novos ajustes na sintonia até obter o desempenho adequado (também utilizando procedimentos heurísticos).

Os principais parâmetros de sintonia do controlador preditivo multivariável do tipo DMC são os seguintes:

1. Horizonte de Predição (P): deve ser escolhido considerando a dinâmica mais lenta do processo em questão. Alguns autores sugerem usar o maior valor do tempo morto somado com cinco vezes a constante de tempo, dividido pelo período de amostragem escolhido. Assim, este parâmetro é definido em função do processo a ser controlado e deve considerar toda a resposta dinâmica – contemplar a predição de todos os efeitos das ações de controle passadas, pois, se for truncado, ele irá gerar erros na predição com impactos no desempenho e na robustez do algoritmo.
2. Horizonte de controle (M): costuma ser um valor maior ou igual a 1. Se o horizonte de controle for igual a 1, o controlador tenderá a ser lento e com baixo desempenho. Por outro lado, quanto maior o horizonte de controle, maior o esforço computacional. É muito comum, na prática, a escolha de M ser maior ou igual a 2, dependendo do algoritmo. Para algoritmos do tipo DMC, é comum utilizar o horizonte de predição (P) três vezes maior que M.
3. Período de amostragem (T): deve ser escolhido em função da dinâmica do processo. Alguns autores, por exemplo, sugerem o menor valor para todos os canais “ij” (manipulada “i” com controlada “j”) do seguinte cálculo: maior valor entre a metade do tempo morto e 10% da constante de tempo deste canal.
4. Pesos nas variáveis manipuladas (R – matriz de supressão de movimento): é o principal parâmetro de sintonia do controlador na prática. O aumento destes pesos leva a uma resposta mais suave da planta e uma maior robustez. Na prática utiliza-se muitas vezes o método de tentativas e erros até obter uma resposta adequada.
5. Pesos nas variáveis controladas (W): são utilizadas para normalizar, compatibilizar as faixas das medições e principalmente para priorizar as variáveis controladas mais importantes.

Diante do apresentado, no geral, quanto maior o horizonte de predição, maior poderá ser a suavidade no controle. Quanto maior o horizonte de controle, mais agressiva pode ser a consequência das ações do controlador sobre as variáveis controladas, uma vez que existe maior liberdade para atuar nas variáveis manipuladas, no entanto, o esforço computacional requerido será maior. Além disso, aumentando-se o horizonte de controle, tende-se também diminuir a amplitude das ações realizadas sobre as variáveis manipuladas.

No que diz respeito às vantagens do controle preditivo baseado em model (MPC), Kwong (2012b, p. 12) inúmera:

1. É uma estratégia de controle geral para processos MIMO com restrições de desigualdade nas variáveis de entrada e saída;
2. Pode acomodar facilmente comportamentos dinâmicos pouco comuns ou difíceis, tais como tempo morto grande e resposta inversa;
3. Desde que as ações de controle são calculadas com base na performance de sistemas de controle otimizante, o MPC pode ser prontamente integrado com estratégias de otimização on-line para otimizar a performance da planta;
4. A estratégia de controle pode ser facilmente atualizada em linha para compensar mudanças nas condições do processo, restrições ou critério de performance.

Já para as desvantagens, tem-se (KWONG, 2012b, p.12):

1. A estratégia MPC é bastante diferente das estratégias de controle multimalhas convencionais e, assim, inicialmente não é familiar aos operadores da planta;
2. Os cálculos MPC podem ser relativamente complicados, pois demandam, por exemplo, resolver um problema Programação Linear ou Programação Quadrática a cada instante de amostragem, necessitando, assim, de uma quantidade significativa de esforço e recursos computacionais;
3. O desenvolvimento de um modelo dinâmico a partir de dados da planta consome muito tempo e tipicamente requer de uma a três semanas de testes na planta;
4. Desde que geralmente são usados modelos empíricos, eles são válidos somente na faixa de condições que foram consideradas durante os testes;

5. Estudos teóricos têm demonstrado que MPC pode ter desempenho fraco para alguns tipos de distúrbio do processo, especialmente quando são consideradas as restrições na saída.

3 APLICAÇÃO DO CONTROLE PREDITIVO MULTIVARIÁVEL

Para atingir o objetivo proposto neste trabalho, utilizou-se como instrumento a análise de um caso cujo problema de controle tem sido muito utilizado para investigar o desempenho de estratégias de controle. Trata-se de uma coluna de destilação binária, em escala piloto, com 8 pratos mais o refeedor, apresentada por Wood e Berry (1973, p. 1717) e empregada para a separação de uma mistura de metanol e água onde as concentrações de metanol nos produtos de topo e de fundo, $x_D(s)$ e $x_B(s)$, respectivamente, são controladas pela manipulação das vazões de refluxo, $R(s)$, e de vapor para o refeedor, $S(s)$.

A matriz de transferência da coluna é expressa pela equação (25):

$$\begin{bmatrix} x_D(s) \\ x_B(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s + 1} & \frac{-18,9e^{-3s}}{21,0s + 1} \\ \frac{6,6e^{-7s}}{10,9s + 1} & \frac{-19,4e^{-3s}}{14,4s + 1} \end{bmatrix} \begin{bmatrix} R(s) \\ S(s) \end{bmatrix} + \begin{bmatrix} \frac{3,8e^{-8s}}{14,9s + 1} \\ \frac{4,9e^{-3s}}{13,2s + 1} \end{bmatrix} [F(s)] \quad (25)$$

O significado físico das variáveis, bem como as condições nominais de operação estão apresentadas na Tabela 1. As constantes de tempo e os tempos mortos são expressos em minutos.

Tabela 1 - Variáveis da coluna Metanol/Água

Variáveis	Descrição	Estado estacionário
$x_D(s)$	Composição de topo	96,25 mol% metanol
$x_B(s)$	Composição de fundo	0,50 mol% metanol
R	Vazão de refluxo	1,95 lb/min
S	Vazão de vapor	1,71 lb/min
F	Vazão de alimentação	2,45 lb/min

Nos anexos, baseados nos trabalhos de Kwong (2012b, p. 93-96) e Seborg e Mellichamp (2010, p. 40), são apresentados o *script* MPCR que resolve um problema regulatório, ou seja, que avalia a rejeição do sistema frente a uma perturbação no distúrbio, bem como o *script* MPCS que resolve um problema servo que envolve a rejeição frente a uma perturbação nos *setpoints*. Ambos utilizam as

rotinas *poly2tfd*, *tfd2step*, *mpccon* e *mpcsim* da caixa de ferramentas *Model Predictive Control* do Matlab®.

A rotina *mpcsim* resolve problemas de controle preditivo sem restrições, e uma descrição da rotina pode ser obtida digitando *help mpcsim* na janela de comando do Matlab®. As instruções citadas estão apresentadas no Anexo, bem como todas as outras comentadas na sequência.

Para realizar a implementação sugerida, o primeiro passo é obter as matrizes de resposta ao degrau da planta real e do modelo, *plant* e *model*, respectivamente. Para obter tais modelos usa-se a rotina *tfd2step*, que gera esses modelos a partir de funções de transferência, as quais podem ser obtidas usando a rotina *poly2tfd*, sendo que os seus dois primeiros argumentos correspondem aos coeficientes dos polinômios no numerador e no denominador da função de transferência e o terceiro argumento 0 significa forma de função de transferência contínua e o argumento final é o tempo morto. Além disso, é preciso fornecer a matriz de ganhos do controlador *Kmpc*, que é obtida usando a rotina *mpccon*, que tem como argumentos: *model* (matriz dos coeficientes da resposta ao degrau do modelo), *ywt* (matriz de ponderação das saídas), *uwt* (matriz de ponderação das entradas), *M* (horizonte de controle) e *P* (horizonte de predição).

Por fim, na Tabela 2 estão apresentados os parâmetros utilizados nas simulações e na próxima seção estão os resultados obtidos.

Tabela 2 - Parâmetros do Controlador

Parâmetros do Controlador	Valores utilizados nas simulações
Horizonte de Predição (P)	8
Horizonte de Controle (M)	1, 3, 7, 8
Pesos das variáveis de saída	Com e sem ponderação
Pesos das variáveis de entrada	Com e sem ponderação

4 RESULTADOS E DISCUSSÕES

Obter a resposta ao degrau da planta real e do modelo, *plant* e *model*, respectivamente, é um dos primeiros passos para implementação que foi realizada. As Figuras 7 e 8, mostram as curvas respostas para perturbações em ambas as variáveis manipuladas, R e S, ou seja, u_1 e u_2 que estão nos gráficos.

As linhas do 6 a 9 e 14 a 18 do *script* MPC.S.m, conferem as respostas mencionadas. É importante lembrar que não há informações de uma planta real, portanto, no algoritmo *plant* é igual a *model*, conforme linha 20 do referido *script*.

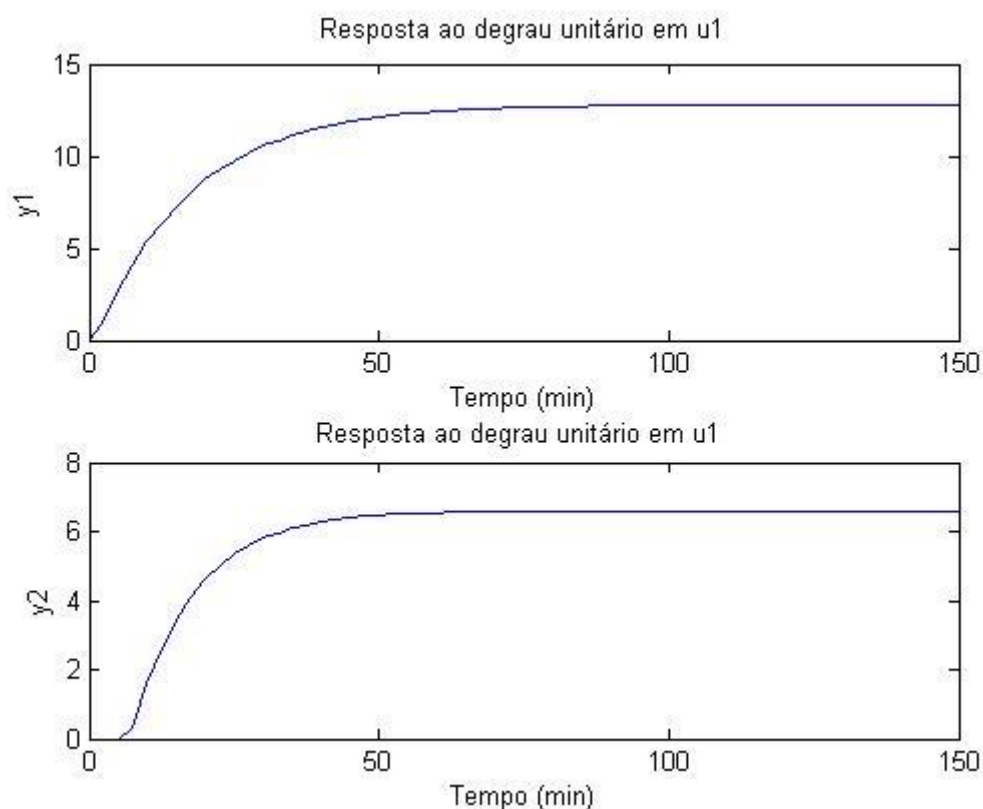


Figura 8 - Resposta ao degrau unitário na variável manipulada (vazão de refluxo)




Figura 9 - Resposta ao degrau unitária na variável manipulada S (Vazão de vapor no refeedor)

Analisando-se, primeiramente o controle servo. Um período de amostragem de 2,5 min foi utilizado e para o horizonte de predição, ficou estabelecido $P = 8$, segundo Kwong e Odloak (1992) que determinaram que este é um valor razoável para o estudo de caso estudado.

Na sequência são mostradas as figuras contendo os gráficos das respostas em malha fechada de alguns casos. A Figura 10 diz respeito ao chamado protótipo mínimo, em que o horizonte de controle é igual ao horizonte de predição, isto é, $M = P$. Ainda que exista um acompanhamento perfeito dos *setpoints* ($y1 = 1$ e $y2 = 0$), as variáveis manipuladas oscilam violentamente (*ringing*). Tal comportamento pode ser minimizado utilizando-se um horizonte de predição maior do que o horizonte de controle. As Figuras de 10 a 13, ilustram o que foi apresentado.

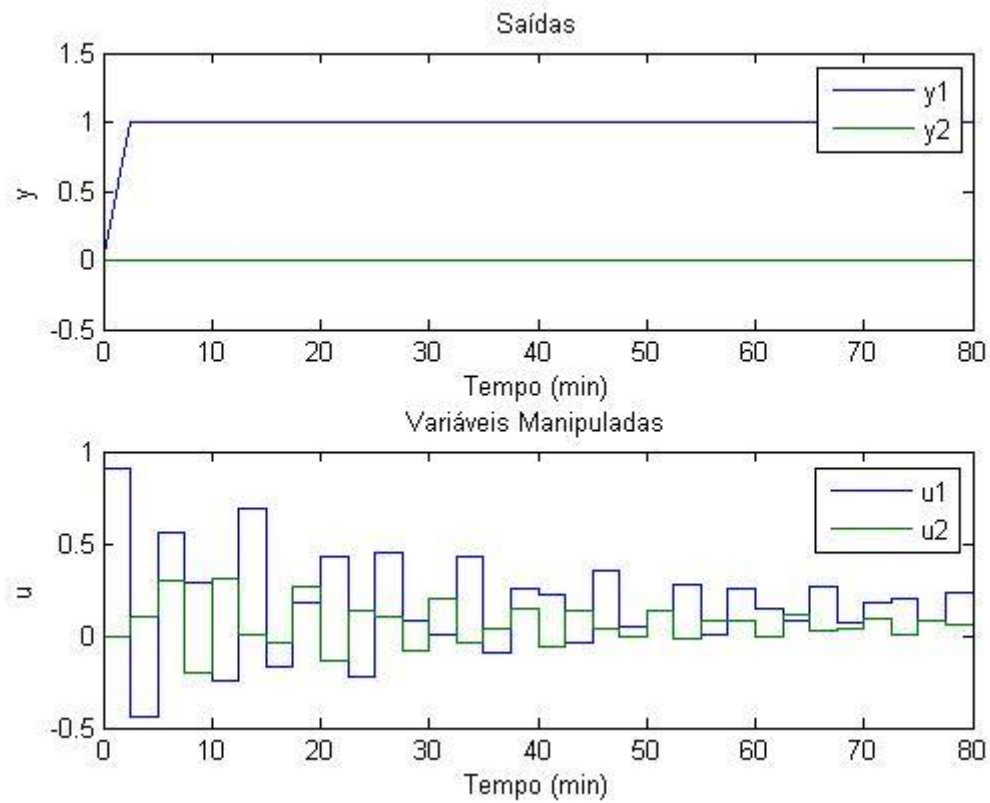


Figura 10 - Controle servo da coluna com $P = 8$ e $M = 8$




Figura 11 - Controle servo da coluna com $P = 8$ e $M = 7$

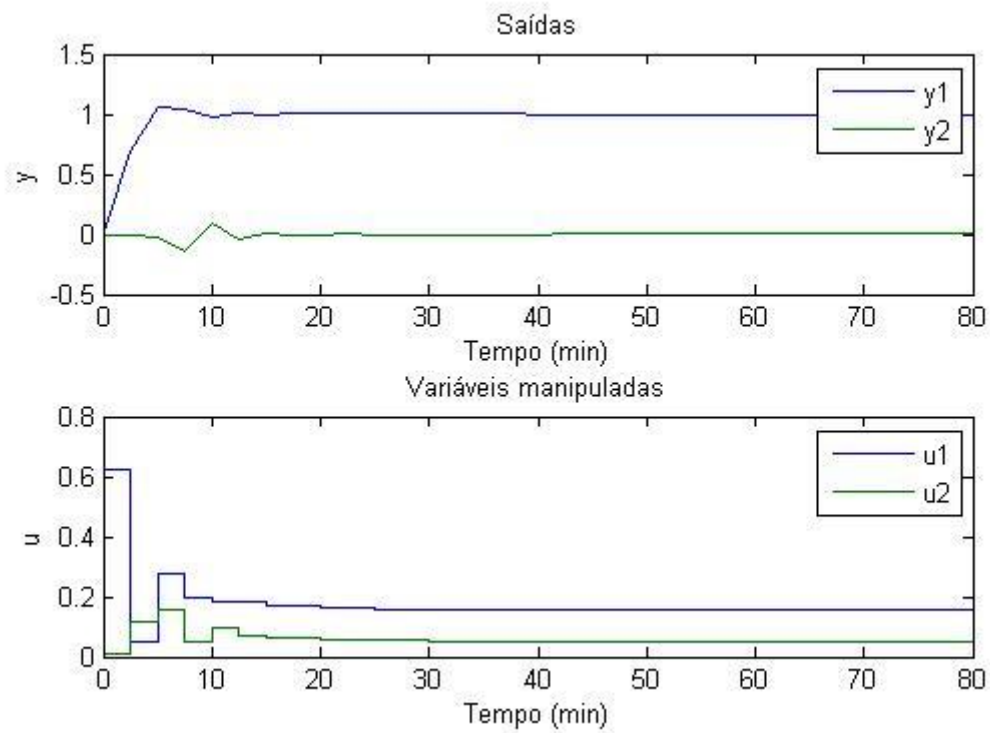


Figura 12 - Controle servo da coluna com $P = 8$ e $M = 3$

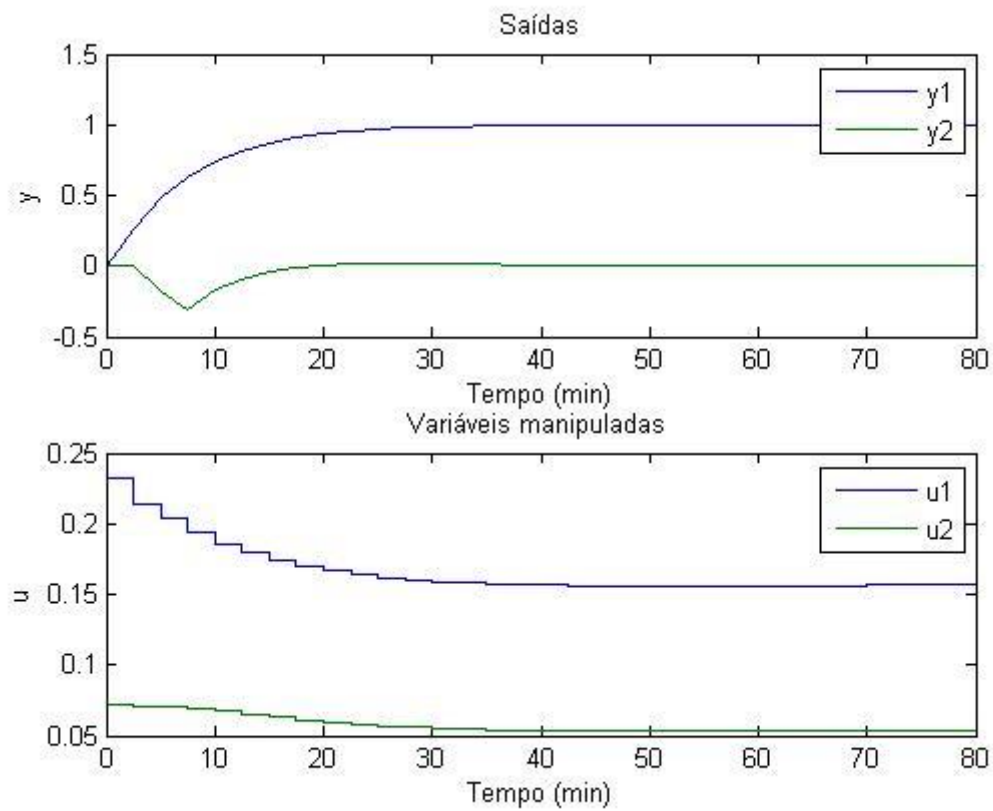


Figura 13 - Controle servo da coluna com $P = 8$ e $M = 1$

É possível ponderar os movimentos de controle por intermédio da matriz de peso dos incrementos nas variáveis manipuladas. A linha 65 do *script* MPCs.m, ilustra como essa ponderação é implementada. Os resultados na Figura 14 mostram que houve uma melhora significativa no projeto protótipo mínimo do controle servo ($M = P$) com essas ponderações em relação ao mesmo projeto sem o uso desse recurso dado na Figura 10.

Há outra maneira de minimizar o *ringing* que é dividir o horizonte de controle em vários subhorizontes de controle, onde em cada um deles, a variável manipulada se mantém inalterada, havendo apenas variações de um sub-horizonte para outro. Foi usado três sub-horizontes, o primeiro formado por 1 período de amostragem, o segundo por 2 períodos de amostragem e o terceiro por 3. Os resultados aparecem na Figura 15, notando-se que o *ringing* foi bem reduzido.

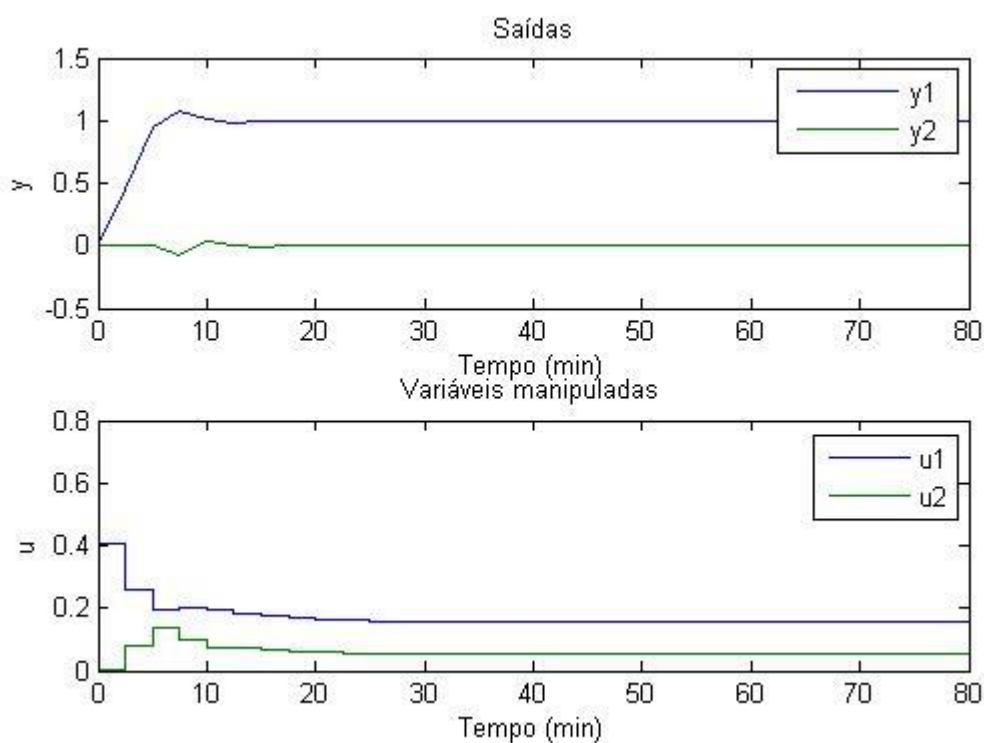


Figura 14 - Controle servo da coluna com $P = 8$ e $M = 8$, minimizando o *ringing* ponderando as entradas

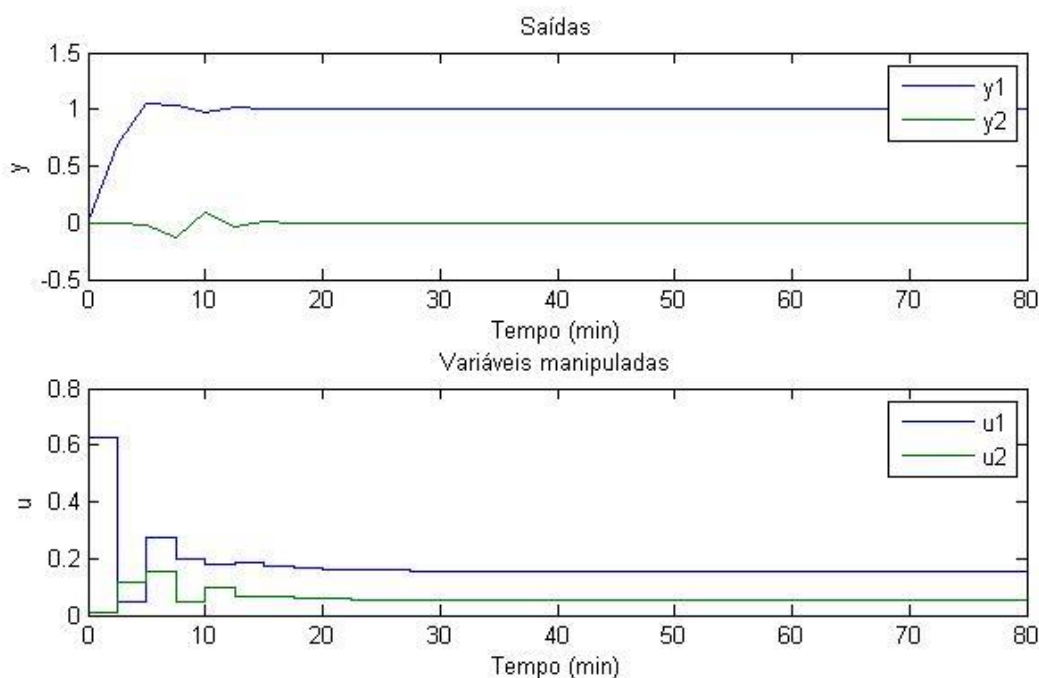


Figura 15 - Controle servo da coluna com $P = 8$ e usando o recurso blocking com $M = [1,2,3]$

O *script* MPCR simula um problema regulatório, ou seja, trata de como o controlador responde a uma variação degrau unitário no distúrbio (controle regulatório). Nota-se que, para esse caso, os *setpoints* são zero. Os resultados estão mostrados na Figura 16, concluindo que, embora as duas saídas voltem a zero, as respostas são muito lentas. Isso pode ser melhorado, por exemplo, medindo também o distúrbio e adicionando a ação antecipatória no algoritmo de controle DMC. O *script* MPCRM, em anexo, simula esse caso, cujos resultados são mostrados na Figura 17, sendo possível notar que o desempenho do controlador melhorou sensivelmente, diminuindo os desvios e o tempo de resposta.

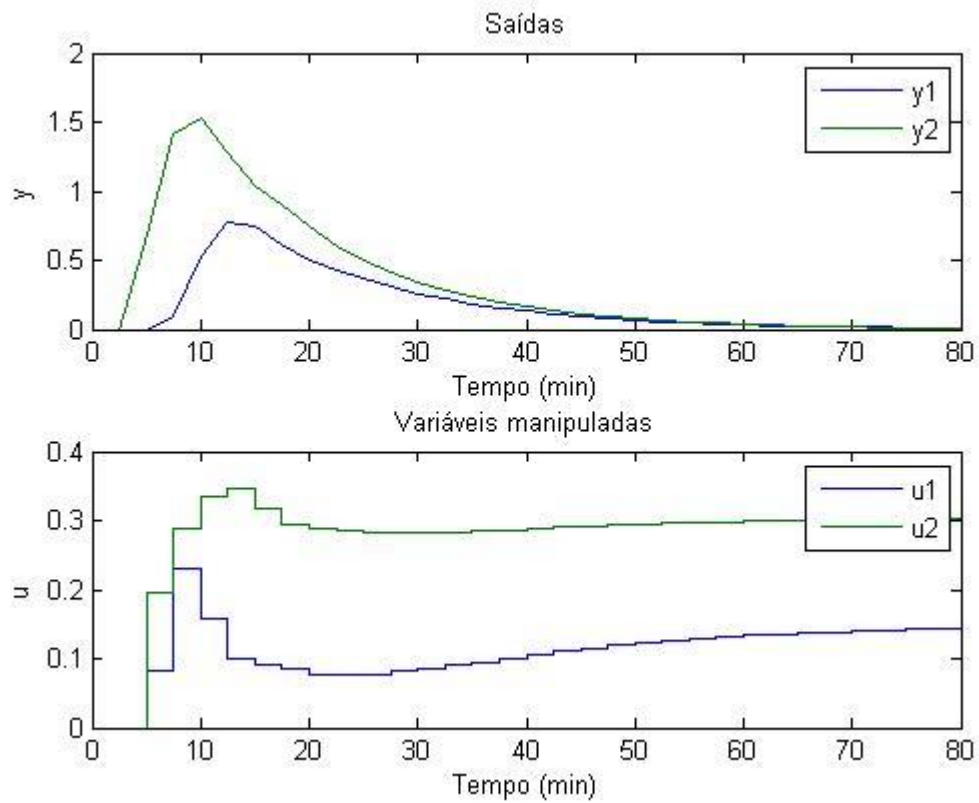


Figura 16 - Controle Regulatório da coluna com $P = 5$ e $M = 5$

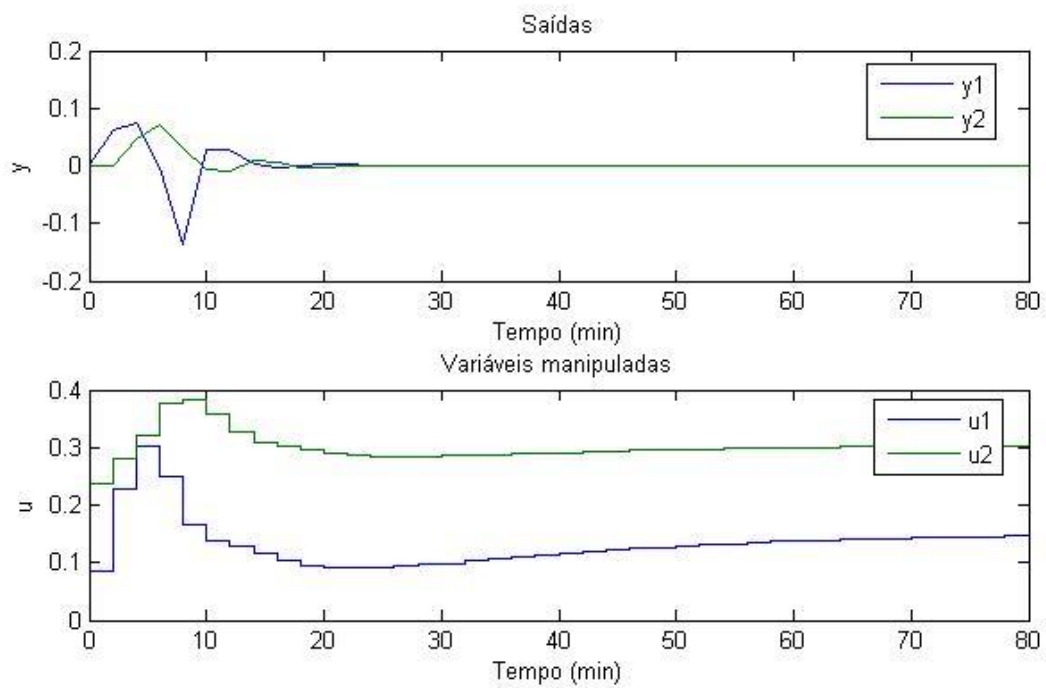


Figura 17 - Controle Regulatório da coluna com $P = 5$ e $L = 5$ e com ação antecipatória

5 Conclusão

Com base na revisão da literatura em que foram apresentados os aspectos básicos do Controle Preditivo, pode-se ter uma ideia das possibilidades que esta estratégia oferece. Assim, as perspectivas de aplicações industriais de tecnologias de controle avançado, sobretudo, quando associado a camada de otimização de processos em tempo real são muito grandes. As exigências cada vez maiores por unidades seguras, rentáveis, flexíveis e sustentáveis abrem espaço para a utilização cada vez maior destes sistemas.

Foi verificado que o controle avançado também é uma estratégia que não está livre de pontos críticos e por isso ainda é muito estudado, ou seja, ele não está livre de desvantagens, tais como: a necessidade de equipe capacitada para implementar, e principalmente para manter os sistemas de controle com um desempenho aceitável, bem como a necessidade de novas ferramentas (algoritmos avançados de controle) e sensores em função das características particulares de cada processo, por exemplo, não linearidades, variação no tempo, entre outras.

Além disso, é importante lembrar que o controle *feedback* clássico continua tendo a sua tradicional importância, sobretudo no controle regulatório dos sistemas, além disso, como ficou observado ao longo do texto, a obtenção dos modelos do processo é a etapa mais importante para implementar sistemas com controle preditivo. No entanto, modelos ruins podem ser superados ou amenizados, às vezes, pelo controle *feedback*, lembrando que “*feedback* pode superar alguns efeitos de modelos ruins, mas partir de um modelo de processo ruim, é semelhante a dirigir um carro à noite sem faróis”.

Por fim, no estudo de caso se pode visualizar como fazer um projeto simples do sistema de controle preditivo utilizando o pacote *Model Predictive Control Toolbox™* do Matlab®, foram apresentados os principais parâmetros sintonizáveis deste tipo de estratégia, como por exemplo, horizonte de predição, horizonte de controle, tempo de amostragem, entre outros e os efeitos dessas escolhas sobre a resposta do sistema, conforme discutido na seção 4, através de simulações.

Conclui-se que a estratégia avançada de controle, tal qual a clássica *feedback*, também é fortemente dependente dos processos de sintonia, sendo que

não é raro se ter sistemas com comportamento proibitivos porque o controlador está mal sintonizado. Portanto, conhecer os parâmetros ajustáveis é importante para se obter desempenhos satisfatórios.

6 Sugestão para trabalhos futuros

- Comparar o desempenho do controle preditivo multivariável com o controle regulatório (PID) na mesma coluna de destilação.

REFERÊNCIAS

AGUIRRE, Luis Antonio. **Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais**. Belo Horizonte: Ed. UFMG, 2000.

BEQUETTE, B. Wayne. **Process Dynamics: modeling, Analysis and simulation**. New Jersey: Prentice Hall, 1998.

CAMPOS, Mario Cesar M. Massa, GOMES, Marcos Vinicius de Carvalho, PEREZ, José Manuel Gonzales Tubio. **Controle avançado e otimização na indústria do petróleo**. 1ª ed. Rio de Janeiro: Interciência, 2013.

INGHAM, John.; et al. **Chemical Engineering Dynamics: An Introduction to Modelling and Computer Simulation**. 3th, WILEY-VCH Verlag GmbH & Co, 2007.

KWONG, Wu Hong. **Introdução ao controle de processos químicos com MATLAB**. São Carlos: EdUFSCar, Volume 1, 2012a.

KWONG, Wu Hong. **Introdução ao controle preditivo com MATLAB**. São Carlos: EdUFSCar, 2012b.

KWONG, Wu Hong; ODLOAK, Darci. **Estudo comparativo do controle por matriz dinâmica não restringido com controlador PI**. In: CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA, 9. 1992. Salvador. Anais...Salvador, v. I, p. 498-507, 1992.

LUYBEN, William. L. **Process modeling, simulation and control for Chemical engineers**. 2 ed. New York: McGraw-Hill, 1996.

PERLINGEIRO, Carlos Augusto Guimarães. **Engenharia de Processos: Análise, simulação, otimização e síntese de processos químicos**. São Paulo: Blucher, 2005.

SEBORG, Dale E.; et al. **Process dynamics and control**. New York: John Wiley and Sons, 2010.

TURTON, Richard; et al. **Analysis, synthesis, and design of Chemical processes**. 3th edition. Prentice Hall PTR. 2009.

WANG, Qing-Guo; et al. **PID Control for Multivariable Processes**. Springer, 2008.

WOOD, R. K.; BERRY, M. W. **Terminal composition control of a binary distillation column**. Chemical Engineering Science, Alberta, v. 28, p. 1707-1717, 1973.

ANEXOS

Script MPCs.m

```

1. %Coluna de Wood e Berry (Problema Servo)
2. %Resposta do sistema frente a um perturbação no Setpoint

3. echo on
4. clear all

5. %Funções de Transferência do Processo
6. Gp11 = poly2tfd(12.8, [16.7 1], 0, 1);
7. Gp12 = poly2tfd(-18.9, [21.0 1], 0, 3);
8. Gp21 = poly2tfd(6.6, [10.9 1], 0, 7);
9. Gp22 = poly2tfd(-19.4, [14.4 1], 0, 3);

10. %Funções de Transferência do Distúrbio
11. Gd1 = poly2tfd(3.8, [14.9 1], 0, 8);
12. Gd2 = poly2tfd(4.9, [13.2 1], 0, 3);

13. % Modelos de resposta ao degrau. Período de amostragem de 2,5

14. T = 2.5; % intervalo de amostragem
15. ny = 2; % número de saídas
16. tfinal = 150; % tempo final do teste

17. plant = tfd2step(tfinal, T, ny, Gp11, Gp21, Gp12, Gp22);
18. plotstep(plant)

19. % Calcula a matriz de ganhos do controlador MPC para sem
    discrepância %modelo/planta

20. model = plant;
21. ywt = []; % default pesos em ambas as saídas
22. uwt = []; % default (zero) peso na entrada
23. P = 8; % horizonte de predição
24. M = P; % horizonte de controle (protótipo mínimo)
25. Kmpc = mpcccon(model, ywt, uwt, M, P);

26. % Simula degrau unitário no setpoint da saída #1 e plota os
    resultados

27. tend = 80; % tempo de simulação
28. r = [1 0]; % setpoints para a entrada
29. [y, u] = mpcsim(plant, model, Kmpc, tend, r);
30. plotall(y, u, T)

31. %Tecle a barra de espaço bar para continuar
32. pause

```

```

33.      %Mantém o horizonte de predição e diminui o horizonte de
        controle para minimizar o ringing

34.      P = 8;
35.      M = 7;
36.      Kmpc = mpcccon(model,ywt,uwt,M,P);
37.      [y,u] = mpcsim(plant,model,Kmpc,tend,r);
38.      plotall(y,u,T)

39.      %Tecle a barra de espaço bar para continuar
40.      pause

41.      % %Mantém o horizonte de predição e diminui o horizonte de
        controle para minimizar o ringing

42.      P = 8;
43.      M = 3;
44.      Kmpc = mpcccon(model,ywt,uwt,M,P);
45.      [y,u] = mpcsim(plant,model,Kmpc,tend,r);
46.      plotall(y,u,T)

47.      %Tecle a barra de espaço bar para continuar
48.      % pause

49.      % %Mantém o horizonte de predição e diminui o horizonte de
        controle para minimizar o ringing

50.      P = 8;
51.      M = 1;
52.      Kmpc = mpcccon(model,ywt,uwt,M,P);
53.      [y,u] = mpcsim(plant,model,Kmpc,tend,r);
54.      plotall(y,u,T)

55.      %Tecle a barra de espaço bar para continuar
56.      pause

57.      %Reduzir ainda usando blocking

58.      M = [1 2 3];          %define 3 blocos de movimentos de controle
59.      Kmpc = mpcccon(model,ywt,uwt,M,P);
60.      [y,u] = mpcsim(plant,model,Kmpc,tend,r);
61.      plotall(y,u,T)

62.      %Tecle a barra de espaço bar para continuar
63.      pause

64.      %Agora aumentando os pesos sobre as entradas

65.      uwt = [1 1];          %aumenta a ponderação nas entradas
66.      P = 8;                %horizonte de predição original
67.      M = P;                %horizonte de controle original
68.      Kmpc = mpcccon(model,ywt,uwt,M,P);
69.      [y,u] = mpcsim(plant,model,Kmpc,tend,r);

```

```
70.     plotall(y,u,T)
71.     echo off
```

Script MPCR.m

```
1. %Coluna de Wood e Berry
2. %Resposta do sistema frente a uma perturbação no distúrbio
3. %(problema regulatório)

4. echo on
5. clear all

6. %Funções de Transferência do Processo
7. Gp11 = poly2tfd(12.8,[16.7 1],0,1);
8. Gp12 = poly2tfd(-18.9,[21.0 1],0,3);
9. Gp21 = poly2tfd(6.6,[10.9 1],0,7);
10.     Gp22 = poly2tfd(-19.4,[14.4 1],0,3);

11.     %Funções de Transferência do Distúrbio
12.     Gd1 = poly2tfd(3.8,[14.9 1],0,8);
13.     Gd2 = poly2tfd(4.9,[13.2 1],0,3);

14.     % Modelos de resposta ao degrau para um período de amostragem
        de 2,5

15.     T = 2.5;           % intervalo de amostragem
16.     ny = 2;           % número de saídas
17.     tfinal = 150;     % tempo final do teste

18.     plant = tfd2step(tfinal,T,ny,Gp11,Gp21,Gp12,Gp22);
19.     plotstep(plant)
20.     dplant = tfd2step(tfinal,T,ny,Gd1,Gd2);
21.     plotstep(dplant)

22.     %Cálcula a matriz de ganhos do controlador MPC para sem
        discrepância modelo/planta

23.     model = plant;
24.     ywt = [1 1];      % pesos das saídas
25.     uwt = [1 1];      % pesos das entradas
26.     P = 5;           % horizonte de predição
27.     M = P;           % horizonte de controle (protótipo min.)
28.     Kmpc = mpcccon(model,ywt,uwt,M,P);

29.     %Simula degrau unitário no setpoint da saída #1 e plota os
        resultados

30.     tend = 80;        % tempo de simulação
31.     r = [0 0];        % setpoints para as duas entradas
32.     usat = [];
33.     tfilter = [];
```



```

34.     dmodel = [];
35.     dstep = 1;
36.     [y,u] =
mpcsim(plant,model,Kmpc,tend,r,usat,tfilter,dplant,dmodel,dstep);
37.     plotall(y,u,T)

38.     echo off

```

Script MPCRM.m

```

%Coluna de Wood e Berry
%Resposta do sistema frente a uma perturbação no distúrbio
%(problema regulatório) com ação antecipatória

echo on
clear all

%Funções de Transferência do Processo
Gp11 = poly2tfd(12.8,[16.7 1],0,1);
Gp12 = poly2tfd(-18.9,[21.0 1],0,3);
Gp21 = poly2tfd(6.6,[10.9 1],0,7);
Gp22 = poly2tfd(-19.4,[14.4 1],0,3);

%Funções de Transferência do Distúrbio
Gd1 = poly2tfd(3.8,[14.9 1],0,8);
Gd2 = poly2tfd(4.9,[13.2 1],0,3);

% Modelos de resposta ao degrau para um período de amostragem de 2,5

T = 2;           % intervalo de amostragem
ny = 2;          % número de saídas
tfinal = 150;    % tempo final do teste

plant = tfd2step(tfinal,T,ny,Gp11,Gp21,Gp12,Gp22);
plotstep(plant)
dplant = tfd2step(tfinal,T,ny,Gd1,Gd2);
plotstep(dplant)

%Calcula a matriz de ganhos do controlador MPC para sem discrepância
%modelo/planta

model = plant;
ywt = [1 1];     % pesos das saídas
uwt = [1 1];     % pesos das entradas
P = 5;           % horizonte de predição
M = P;           % horizonte de controle (protótipo mínimo)
Kmpc = mpcccon(model,ywt,uwt,M,P);

%Simula degrau unitário no setpoint da saída #1 e plota os resultados

tend = 80;       % tempo de simulação
r = [0 0];       % setpoints para as duas entradas
usat = [];
tfilter = [];
dmodel = dplant; %distúrbio medido

```

```

dstep = 1;
[y,u] = mpcsim(plant,model,Kmpc,tend,r,usat,tfilter,dplant,dmodel,dstep);
plotall(y,u,T)

echo off

```

```
>> help mpcsim
```

mpcsim Simulation of the unconstrained Model Predictive Controller.

```
[y,u,ym] = mpcsim(plant, model, Kmpc, tend, r,usat, tfilter, dplant, dmodel, dstep)
```

REQUIRED INPUTS:

plant(model): the step response coefficient matrix of the plant (model) generated by the function `tfd2step`.

Kmpc: the constant control law matrix computed by the function `mpccon` (closed-loop simulations). For open-loop simulation, `controller=[]`.

tend: final time of simulation.

r: for the closed-loop simulation, it is a constant or time-varying reference trajectory. For the open-loop simulation, it is the trajectory of the manipulated variable `u`.

OPTIONAL INPUTS:

usat: the matrix of manipulated variable constraints. It is a constant or time-varying trajectory of the lower limits (`Ulow`), upper limits (`Uhigh`) and rate of change limits (`DelU`) on the manipulated variables. Default=`[]`.

tfilter: time constants for noise filter and unmeasured disturbance lags.

Default is no filtering and step disturbance.

dplant: step response coefficient matrix for the disturbance effect on the plant output generated by the function `tfd2step`. If `distplant` is provided, `dstep` is also required. Default = `[]`.

dmodel: step response coefficient matrix for the measured disturbance effect on the model output generated by the function `tfd2step`.

If `distmodel` is provided, `dstep` is also required. Default=`[]`.

dstep: matrix of disturbances to the plant. For output step disturbances

it is a constant or time-varying trajectory of disturbance values

For disturbances through step response models, it is a constant or time-varying trajectory of disturbance model inputs. Default=`[]`.

OUTPUT ARGUMENTS: `y` (system response), `u` (manipulated variable) and `ym` (model response)

See also `plotall`, `ploteach`, `cmpec`, `mpccl`, `mpccon`.

>> help poly2tfd

poly2tfd Create transfer functions in 3 row representation

`g = poly2tfd(num,den,delt,delay)`

poly2tfd creates a MPC toolbox transfer function in following format:

```
g = [ b0 b1 b2 ... ] (numerator coefficients)
     | a0 a1 a2 ... | (denominator coefficients)
     [ delt delay 0 ... ] (only first 2 elements used in this row)
```

Inputs:

num: Coefficients of the transfer function numerator.

den: Coefficients of the transfer function denominator.

delt: Sampling time. Can be 0 (for continuous-time system) or > 0 (for discrete-time system). Default is 0.

delay: Pure time delay (dead time). Can be >= 0.

If omitted or empty, set to zero.

For discrete-time systems, enter as PERIODS of pure delay (an integer). Otherwise enter in time units.

>> help tfd2step

tfd2step Determines the step response model of a transfer function model.

`plant = tfd2step(tfinal, delt2, nout, g1)`

`plant = tfd2step(tfinal, delt2, nout, g1, ..., g25)`

The transfer function model can be continuous or discrete.

Inputs:

tfinal: truncation time for step response model.

delt2: desired sampling interval for step response model.

nout: output stability indicator. For stable systems, this argument is set equal to number of outputs, `ny`.

For systems with one or more integrating outputs, this argument is a column vector of length n_y with

$n_{out}(i)=0$ indicating an integrating output and

$n_{out}(i)=1$ indicating a stable output.

g_1, g_2, \dots : SISO transfer function described above ordered to be read in columnwise (by input). The number of transfer functions required is $n_y \cdot n_u$. (n_u =number of inputs). Limited to $n_y \cdot n_u \leq 25$.

Output:

plant: step response coefficient matrix in MPC step format.

See also `mod2step`, `plotstep`, `ss2step`.

`>> help mpcccon`

`mpcccon` Calculate MPC controller gains for unconstrained case.

`Kmpc = mpcccon(model,ywt,uwt,M,P)`

`mpcccon` uses a step-response model of the process.

Inputs:

`model` : Step response coefficient matrix of model.

`ywt,uwt` : matrices of constant or time-varying weights.

If the trajectory is too short, they are kept constant for the remaining time steps.

`M`: number of input moves and blocking specification. If `M` contains only one element it is the input horizon length. If `M` contains more than one element then each element specifies blocking intervals.

`P`: output (prediction) horizon length. `P = Inf` indicates the infinite horizon.

Output:

`Kmpc`: Controller gain matrix

See also `cmpc`, `mpcccl`, `mpccsim`.
