

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL

LUIS FERNANDO POZAS

**UMA ESTRATÉGIA DE INTEGRAÇÃO DA CAMADA DE
OTIMIZAÇÃO EM TEMPO REAL PARA CONTROLE
HIERÁRQUICO**

TESE

CURITIBA

2018

LUIS FERNANDO POZAS

**UMA ESTRATÉGIA DE INTEGRAÇÃO DA CAMADA DE
OTIMIZAÇÃO EM TEMPO REAL PARA CONTROLE
HIERÁRQUICO**

Tese apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do Título de “Doutor em Ciências” – Área de Concentração: Engenharia de Automação e Sistemas.

Orientadora: Profa. Dra. Lúcia Valéria Ramos de Arruda

CURITIBA

2018

Dados Internacionais de Catalogação na Publicação

P893e
2018 Pozas, Luis Fernando
Uma estratégia de integração de camada de otimização em tempo real para controle hierárquico / Luis Fernando Pozas.-- 2018.
1 arquivo texto (97 f.) : PDF ; 1,1 MB

Texto em português com resumo em inglês
Disponível via World Wide Web
Tese (Doutorado) - Universidade Tecnológica Federal do Paraná.
Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2018
Bibliografia: f. 89-94

1. Controle preditivo. 2. Controle de processo. 3. Controle automático. 4. Processos químicos. 5. Métodos de simulação. 6. Engenharia elétrica - Teses I. Arruda, Lúcia Valéria Ramos de, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD: Ed. 22 – 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba
Bibliotecária : Anna T. R. Caruso CRB9/935

TERMO DE APROVAÇÃO DE TESE Nº 181

A Tese de Doutorado intitulada “**Uma Estratégia de Integração da Camada de Otimização em Tempo Real para Controle Hierárquico**”, defendida em sessão pública pelo(a) candidato(a) **Luis Fernando Pozas** no dia 01 de novembro de 2018, foi julgada para a obtenção do título de Doutor em Ciência, área de concentração Engenharia de Controle e Automação, e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial.

BANCA EXAMINADORA:

Prof(a). Dr(a). Lúcia Valéria Ramos de Arruda – Presidente - (UTFPR)

Prof(a). Dr(a). Gustavo Henrique Costa Oliveira – (UFPR)

Prof(a). Dr(a). Flavio Neves Jr. – (UTFPR)

Prof(a). Dr(a). Ilca Maria Ferrari Ghiggi – (IFSC)

Prof(a). Dr(a). Ricardo Luders - (UTFPR)

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 01 de novembro de 2018.

Dedico a todos aqueles que lutam por melhorar o ensino público brasileiro.

AGRADECIMENTOS

Agradeço ao IFSC e à UTFPR pela confiança depositada em mim e pela oportunidade de desenvolver este trabalho, o que não seria possível sem o convênio DINTER-CAPES entre as duas instituições. Agradeço também em particular à orientadora pelas dicas e por estar sempre à disposição.

RESUMO

POZAS, Luis Fernando. UMA ESTRATÉGIA DE INTEGRAÇÃO DA CAMADA DE OTIMIZAÇÃO EM TEMPO REAL PARA CONTROLE HIERÁRQUICO. 97 f. Tese – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2018.

Nesta tese desenvolve-se uma estratégia para a integração das camadas pertencentes a um sistema de controle hierárquico. Em particular, é apresentada uma abordagem de integração dinâmica da camada *RTO (Real-Time Optimization)*, ou camada de otimização em tempo real (camada superior), com a camada *Supervisório*, ou camada de controle preditivo (camada inferior), através de uma camada intermediária, ou subcamada, que é conhecida como *SSTO (Steady-State Target Optimization)*, ou Otimização de Alvos de Estado Estacionário. Esta estrutura de controle permite harmonizar as transições de *setpoints* obtidas pelo rastreamento econômico, e manter a estabilidade do sistema. A utilização compartilhada no controlador preditivo e na subcamada, de modelos lineares simples, de uso difundido na indústria, e que são continuamente identificados a partir das variáveis do processo, permite o usufruto das vantagens da estrutura de controle em qualquer ponto de operação do sistema, até mesmo em cenários não previstos, bem como facilita a implementação em ambiente industrial. A estratégia proposta é implementada em dois processos químicos diferentes. Os resultados são promissores e indicam melhoria do rastreamento econômico, suavização das transições e manutenção da estabilidade do sistema.

Palavras-chave: Controle hierárquico, Otimização em tempo real, MPC, SSTO, Identificação

ABSTRACT

POZAS, Luis Fernando. A STRATEGY TO INTEGRATE RTO AND MPC LAYER WITHIN A HIERARCHICAL CONTROL STRUCTURE. 97 f. Tese – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2018.

A hierarchical control layer integration strategy is presented in this document. In particular, it is proposed to use the *SSTO* (*Steady-State Target Optimization*) layer, interfacing the *RTO* (*Real-Time Optimization*) layer and the *MPC* (*Model-Predictive Control*) layer. This control structure smooths economic tracking related setpoint shiftings without losing stability. The use of continuously identified simple linear models - of common use in industry - shared on both *SSTO* and *MPC* layers, allow the advantages obtained by the use of the structure to be available at whatever operating points, even at the ones which were not planned for, as well as paves the way to be used in industrial environment. The strategy is implemented in two different industrial process. Results obtained are promising and shows improvement in economic tracking and smoothening of setpoint shifting, altogether with stable operation of the process.

Keywords: Hierarchical control, RTO, MBPC, SSTO, Identification

LISTA DE FIGURAS

FIGURA 1.1 – Estrutura detalhada de controle hierárquico	16
FIGURA 2.1 – Estrutura de Controle Simplificado	22
FIGURA 2.2 – Típica Coluna de Destilação Binária	23
FIGURA 2.3 – Hierarquia de Controle	25
FIGURA 2.4 – Estrutura detalhada de um sistema <i>RTO</i>	33
FIGURA 2.5 – Estrutura <i>RTO-SSTO-GPC</i>	39
FIGURA 3.1 – Integração <i>RTO-MPC</i> com modelo continuamente identificado	43
FIGURA 3.2 – Diagrama de implementação da estratégia	46
FIGURA 4.1 – Equações das reações químicas	50
FIGURA 4.2 – Partes que compõem o processo	51
FIGURA 4.3 – Tabela com os valores das vazões e concentrações	52
FIGURA 4.4 – Validação do modelo - Vazões mássicas na saída do reator [lb/h]	52
FIGURA 4.5 – Malhas de controle	53
FIGURA 4.6 – Estrutura do modelo utilizado no <i>GPC</i>	54
FIGURA 4.7 – Vazão mássica na saída do reator sistema original x modelo identificado [lb/h]	55
FIGURA 4.8 – Resposta do sistema à uma perturbação quando apenas o <i>GPC</i> está acionado	59
FIGURA 4.9 – Resultado econômico do sistema quando apenas o <i>GPC</i> está acionado ...	60
FIGURA 4.10 – Resposta do sistema a uma perturbação quando <i>RTO-GPC</i> estão acionadas	61
FIGURA 4.11 – Resultado econômico do sistema quando <i>RTO-GPC</i> estão acionadas	61
FIGURA 4.12 – Resposta do sistema à uma perturbação quando <i>RTO-SSTO-GPC</i> estão acionadas	62
FIGURA 4.13 Resultado econômico quando $F_A = +20\%$ e <i>RTO-SSTO-GPC</i> implementada com proximidade a (u_{RTO}, y_{RTO})	65
FIGURA 4.14 Resultado econômico quando $F_A = -20\%$ e <i>RTO-SSTO-GPC</i> implementada com proximidade a (u_{RTO}, y_{RTO})	65
FIGURA 4.15 Resultado econômico quando $F_A = +20\%$ e <i>RTO-SSTO-GPC</i> implementada com rastreamento econômico	66
FIGURA 4.16 Resultado econômico quando $F_A = -20\%$ e <i>RTO-SSTO-GPC</i> implementada com rastreamento econômico	66
FIGURA 5.1 – Diagrama do Reator isotérmico	69
FIGURA 5.2 – Malhas de controle	70
FIGURA 5.3 – Estrutura do modelo utilizado no <i>GPC</i>	71
FIGURA 5.4 – Primeira simulação - Resposta do sistema à perturbação econômica	75
FIGURA 5.5 – Primeira Simulação - Evolução das entradas do sistema em resposta à perturbação econômica	75
FIGURA 5.6 – Primeira simulação - Valor ótimo f_{eco} x Valor atual f_{eco}	76
FIGURA 5.7 – Segunda Simulação - Ex.1 - Evolução das entradas do sistema	78
FIGURA 5.8 – Segunda simulação - Ex.1 - Resposta do sistema à perturbação econômica	78
FIGURA 5.9 – Segunda simulação - Ex.1 - Evolução do retorno econômico	79
FIGURA 5.10 – Segunda simulação - Ex.2 - Evolução das entradas do sistema	79

FIGURA 5.11– Segunda simulação - Ex.2 - Resposta do sistema à perturbação econômica	80
FIGURA 5.12– Segunda simulação - Evolução do retorno econômico	80
FIGURA 5.13– Terceira simulação - Modelo Fixo - Resposta do sistema à perturbação econômica	82
FIGURA 5.14– Terceira simulação - Modelo Variável - Resposta do sistema à perturbação econômica	82
FIGURA 5.15– Terceira Simulação - Modelo Fixo - Evolução do retorno econômico	83
FIGURA 5.16– Terceira Simulação - Modelo Variável - Evolução do retorno econômico .	83

LISTA DE TABELAS

TABELA 4.1 – Velocidade das três reações envolvidas	50
TABELA 4.2 – Modelos identificados para uso no <i>GPC</i>	54
TABELA 5.1 – Tabela com pontos de operação ótimos	74
TABELA 5.2 – Índice Ψ calculado para a simulação 1	77

LISTA DE SIGLAS

IFSC	Instituto Federal de Santa Catarina
UTFPR	Universidade Tecnológica Federal do Paraná
DINTER	Programa de Doutorado Interinstitucional
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
SSTO	Steady-State Target Optimization
MPC	Model-Predictive Control
RTO	Real-Time Optimization
PO	Ponto de Operação
PID	Controlador Proporcional-Integral-Derivativo
NMPC	Nonlinear Model Predictive Control
NLP	NonLinear Programming
PI	Controlador Proporcional-Integral
GPC	Generalized Predictive Control
CARIMA	Controlled Auto-Regressive Integrated Moving Average
RSGi	RTO+SSTO+GPC+identificação
FOPDT	First Order Plus Dead Time
EMPC	Economic Model Predictive Control

SUMÁRIO

1 INTRODUÇÃO	14
1.1 MOTIVAÇÃO	15
1.2 IMPORTÂNCIA DA PESQUISA	16
1.3 OBJETIVOS	18
1.3.1 Objetivo Geral	18
1.3.2 Objetivos Específicos	18
1.4 METODOLOGIA	18
1.5 CONTRIBUIÇÕES DO TRABALHO	19
1.6 ESTRUTURA DO TRABALHO	19
2 FUNDAMENTAÇÃO TEÓRICA	21
2.1 FUNDAMENTAÇÃO TEÓRICA	22
2.1.1 Estrutura Hierárquica de Controle	25
2.2 REVISÃO BIBLIOGRÁFICA	27
2.2.1 Otimização e Controle de Plantas	33
2.2.2 Integração entre <i>RTO</i> e <i>MPC</i>	35
2.2.3 Inclusão de Subcamada Intermediária	39
3 ESTRATÉGIA DE INTEGRAÇÃO PROPOSTA	42
3.1 APRESENTAÇÃO DA ESTRATÉGIA	43
3.2 SEQUÊNCIA DE OPERAÇÕES	46
4 REAÇÃO OTTO	48
4.1 MODELO DE REAÇÃO QUÍMICA IMPLEMENTADO	49
4.2 ESTRATÉGIA <i>RSGi</i> APLICADA À REAÇÃO DE OTTO	52
4.3 RESULTADOS OBTIDOS COM A ESTRUTURA DE CONTROLE	58
4.3.1 Primeira Simulação	59
4.3.2 Segunda Simulação	60
4.3.3 Terceira Simulação	62
4.3.4 Quarta Simulação	63
4.4 DISCUSSÕES	66
5 REATOR ISOTÉRMICO	68
5.1 REATOR ISOTÉRMICO	69
5.2 ESTRATÉGIA <i>RSGi</i> APLICADA À REAÇÃO ISOTÉRMICA	70
5.3 RESULTADOS OBTIDOS COM A ESTRUTURA DE CONTROLE	73
5.3.1 Primeira Simulação	74
5.3.2 Segunda Simulação	77
5.3.3 Segunda Simulação - Exemplo 2	79
5.3.4 Terceira Simulação	81
5.4 DISCUSSÕES	84
6 CONCLUSÃO	85
6.1 PERSPECTIVAS E TRABALHOS FUTUROS	87
REFERÊNCIAS	89
Apêndice A – EQUAÇÕES DINÂMICAS DA REAÇÃO OTTO	95

Apêndice B - AJUSTE DE PARÂMETROS DO GPC	97
---	-----------

1 INTRODUÇÃO

“Changing market conditions enforce chemical processing industries to better utilize process capabilities. Process operation needs to be closely tied with market demand to improve capital productivity ... Intentional dynamic operation of a plant opens opportunities for significant improvement of plant economics and capital productivity. Market driven operation of plants may become feasible, if plant and process designs support it.”

Backx et al. (2000)

Neste capítulo apresentam-se as razões que motivam o tema deste estudo, seguido por uma rápida descrição do problema que está sendo tratado (a divisão de um problema de controle complexo em camadas dispostas dentro de uma estrutura hierárquica), de quais maneiras ele tem sido tratado, ressaltando sua relevância em ambiente acadêmico e industrial, e quais as potencialidades de sua aplicação. Em seguida introduz-se o objetivo geral bem como enumeram-se os objetivos específicos estabelecidos em relação à estratégia proposta para tratar do problema apresentado. A metodologia seguida para o desenvolvimento do trabalho e as contribuições esperadas fecham o capítulo.

1.1 MOTIVAÇÃO

O emprego de estratégias avançadas de controle se torna, cada vez mais, uma necessidade nas indústrias, dada a necessidade de melhorar seus processos produtivos. A evolução do mercado demanda avanços nas práticas operacionais em termos de minimização de custos, aumento de segurança, qualidade, produtividade e flexibilidade na operação, minimização de impactos ao meio ambiente, entre outros, o que por sua vez impulsiona o desenvolvimento e a implantação de novas técnicas de controle que permitam alcançar um alto grau de eficácia e competitividade na operação dos processos.

Em semelhante ponto de vista, Engell (2007) defende que na área de engenharia de processos químicos, a razão mais importante para se utilizar um sistema de controle é a de conseguir extrair, em qualquer situação, o máximo retorno econômico do mesmo. Neste sentido, o autor reforça que o uso desses sistemas é indispensável para que se consiga lidar com as diferenças entre as situações previstas na fase do projeto, e a realidade das plantas industriais, viabilizando o uso extensivo dos equipamentos instalados. Apresentando ideias similares, em (ADETOLA; GUAY, 2010) os autores citam que um dos maiores desafios da indústria de processos é o de conseguir obter a melhor operação das plantas controladas nos diferentes cenários, nos quais as condições da alimentação, a disponibilidade de energia, os preços de matéria-prima e de produtos, a composição desejada dos produtos, entre outros, estão em permanentes mudanças.

Para enfrentar tais desafios, e atingir os objetivos de melhoria dos processos produtivos, utiliza-se na indústria uma estrutura de controle hierárquico padrão (YING; JOSEPH, 1999; BACKX et al., 2000; FRIEDMAN, 2000; TATJEWSKI et al., 2006; TATJEWSKI, 2008; CHACHUAT et al., 2009; MARCHETTI et al., 2014; FERRAMOSCA et al., 2017), apresentada na figura 1.1, onde o problema da produção de produtos que atendam o mercado da melhor forma possível, é subdividido em cinco camadas, cada qual com objetivos bem

definidos. O foco e o horizonte de planejamento alteram-se gradativamente, desde o topo até a base da camada, alocando-se às camadas superiores decisões estratégicas de longo prazo, e às camadas inferiores decisões operacionais de curto prazo. No nível intermediário, tratam-se as questões táticas e de interfaceamento entre os níveis.

GERENCIAMENTO INTEGRADO DE UMA PLANTA

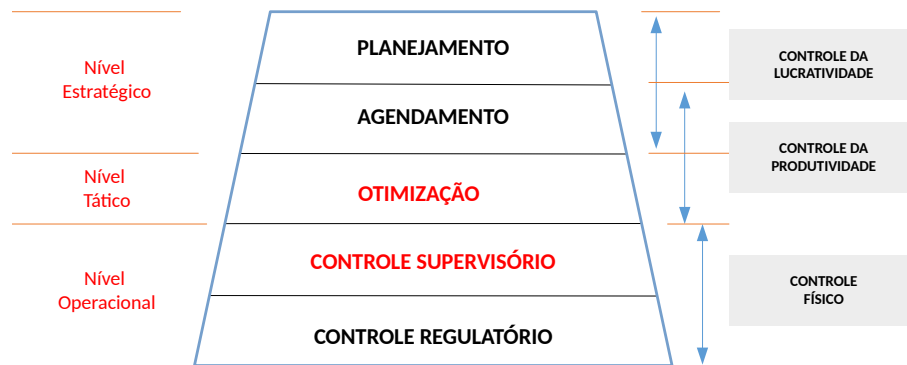


Figura 1.1: Estrutura detalhada de controle hierárquico

Na fronteira entre o nível tático e o operacional situam-se a camada de Otimização, onde se encontra o otimizador em tempo real (em inglês *RTO*), e a camada de Controle Supervisório, onde se encontra o controlador avançado. Estas camadas são de particular interesse no presente estudo, e estão relacionadas às questões já mencionadas nos parágrafos anteriores no que se refere ao uso intensivo dos recursos disponíveis para otimizar os processos produtivos. A definição dos sub-problemas dessas camadas, com seus objetivos e particularidades próprios, e a necessidade de integração na estrutura maior da qual fazem parte, motivam a busca de oportunidades de melhorias que sendo corretamente exploradas, através da definição de uma estratégia de integração apropriada, implicam em ganhos econômicos e aumento de confiabilidade do sistema de controle hierárquico.

1.2 IMPORTÂNCIA DA PESQUISA

Para tratar do problema de controle de toda uma unidade industrial, incluindo aspectos econômicos, de estocagem e de produção, é comum encontrar a subdivisão deste problema global em problemas locais hierarquicamente estruturados, menores, mais simples e com objetivos específicos que quando solucionados, mesmo que individualmente, acabam por solucionar também o problema maior do qual fazem parte. Este conceito se baseia em um estudo sobre complexidade ((SIMON, 1991)), onde o autor discorre sobre a evolução de sistemas complexos e a utilização, nestes sistemas, de organizações hierarquicamente estruturadas em

camadas.

Dentro deste paradigma, a prática usual na indústria no que se refere especificamente à aplicação da otimização junto a estratégias de controle, está baseada na separação destas em duas camadas diferentes (prática conhecida como “*two-layer approach*”), onde uma camada é especializada no problema de otimização e a outra camada no problema de controle. Em quantidade menor encontra-se também algum desenvolvimento de abordagens baseadas na fusão destas duas camadas. A prática usual se torna uma alternativa vantajosa quando comparada com a abordagem alternativa de fusão de camadas, pois nesta última o desenvolvimento de um mecanismo de controle homogêneo, centralizado e abrangente, se torna mais difícil quando aplicado em processos maiores e mais complexos (TATJEWSKI, 2008).

De maneira geral, estas práticas otimizam os recursos envolvidos sem abrir mão da flexibilidade nas operações, que é uma característica muito desejada em alguns setores como, por exemplo, no conjunto de processos dentro de uma unidade de refinaria, onde os *setpoints* são constantemente alterados, conforme alterações no lote de processamento, metas de produção, requisitos de qualidade, etc. De fato, a indústria petroquímica como um todo é um bom exemplo de setor onde a flexibilidade é característica fundamental nos processos produtivos, sem a qual não se consegue maximizar o lucro em resposta à flutuação dos preços no mercado (TSAY et al., 2018).

Na abordagem em duas camadas, a camada superior consiste do *RTO* e a camada inferior consiste do controle Supervisório, para o qual a escolha natural se direciona à implementação de algum algoritmo de controle baseado em modelo, conhecido como *MPC* (do inglês, *Model Predictive Control*) por suas vantagens no tratamento de problemas multivariáveis, e a incorporação natural de restrições nas variáveis de entrada e saída (QIN; BADGWELL, 2003). A camada *RTO* rastreia o ponto de operação (*PO*) ótimo para as condições atualizadas de operação, e a camada inferior direciona a planta controlada no sentido deste *PO*. Em (DARBY et al., 2011), os autores estimaram um número que variava entre 250 a 300 implementações diferentes de *RTO* baseados em pacotes comerciais, número que não incluía obviamente as soluções proprietárias de integração *RTO+MPC*.

Há ainda, na abordagem “*two-layer*”, muitas oportunidades de desenvolvimento e aperfeiçoamento dos métodos e práticas existentes, dentre as quais cita-se a busca por aumentar a frequência de acionamento da camada *RTO*, aumentar a robustez dos sistemas, minimizar as inconsistências dos modelos utilizados nas camadas, efetuar a implementação pioneira em processos novos, criar índices de desempenho econômico, entre outros. Apresentam-se, na revisão bibliográfica da seção 2.2, alguns trabalhos contendo o desenvolvimento destes e de

outros conceitos correlatos.

Pretende-se com este trabalho, em resumo, introduzir técnicas que possam contribuir com a área de controle no setor industrial, através do desenvolvimento de um método de integração *RTO+MPC* mais eficiente, onde ocorra uma frequência maior de rastreamento do *PO* ótimo, que minimize as possíveis inconsistências, e que seja de fácil implementação nos sistemas de controle industriais.

1.3 OBJETIVOS

1.3.1 OBJETIVO GERAL

Estudar a integração das camadas inferiores dentro de uma estrutura hierárquica de controle e propor uma estratégia combinada de identificação, controle e otimização, facilmente implementável, e que permita melhorar o desempenho da estrutura sem trazer riscos à operação.

1.3.2 OBJETIVOS ESPECÍFICOS

- Desenvolver e implementar algoritmos de controle dentro de uma estrutura hierárquica de controle.
- Propor e implementar uma solução original de integração entre as camadas inferiores.
- Avaliar e comparar o desempenho econômico da solução original com soluções encontradas na literatura.
- Desenvolver e implementar um modelo dinâmico de uma reação química padrão da área para servir de *test-bed* aos modelos e algoritmos propostos.

1.4 METODOLOGIA

Descreve-se a seguir a metodologia utilizada ao longo do trabalho, para desenvolver a estratégia de integração de camadas proposta.

Para conseguir avaliar o desempenho da estratégia proposta, a mesma foi utilizada em duas aplicações diferentes. Na primeira aplicação, um processo químico didático, idealizado na década de 60, (WILLIAMS; OTTO, 1960), foi utilizado como *test-bed* para simulações de controle com a estrutura hierárquica proposta, após ser estudado e posteriormente implementado em ambiente matemático *Matlab*[®]. Este processo é representativo de grande

parte dos processos industriais, e portanto, é um bom ponto de partida para verificar a factibilidade, as dificuldades na implementação e as possibilidades de melhorias obtidas através da aplicação da estratégia desenvolvida.

Na segunda aplicação, utilizou-se como base de comparação um trabalho obtido na literatura desenvolvido dentro da abordagem *EMPC*, aplicada a um processo químico em que ocorrem reações paralelas. Este processo químico foi estudado, e posteriormente implementado em ambiente matemático *Matlab*[®], onde a estratégia de integração de camadas foi aplicada. Os resultados obtidos em simulação foram então comparados com o trabalho original, em termos de resultado econômico e estabilidade.

Nas duas aplicações citadas investigou-se o desempenho da estratégia proposta do ponto de vista do rastreamento do ponto ótimo econômico, da suavização das transições de *setpoints*, e da manutenção da controlabilidade do sistema, pontos que são importantes para uma boa prática industrial.

1.5 CONTRIBUIÇÕES DO TRABALHO

Espera-se que a estratégia de integração de camadas proposta possa contribuir com a diminuição do *gap* existente entre as decisões estratégicas e as decisões operacionais, dentro de uma estrutura hierárquica de controle padrão, promovendo a harmonização entre as demandas impostas pelos objetivos concorrentes dos subproblemas das camadas *RTO* e *MPC*, e que melhore o resultado econômico obtido, nos diferentes ambientes industriais em que venha a ser utilizado.

1.6 ESTRUTURA DO TRABALHO

No capítulo 2 apresenta-se uma introdução teórica e revisão bibliográfica do assunto. Parte-se dos princípios da teoria de controle, prosseguindo-se no seu desenvolvimento até atingir a complexidade de sistemas de controle hierarquizados. Menciona-se a utilização de conhecimentos de otimização para melhorar o desempenho de sistemas controlados. Ao final do capítulo apresentam-se as bases teóricas que fundamentam a estratégia de integração proposta.

A estratégia de integração proposta está apresentada no capítulo 3. Há um diagrama estabelecendo a sequência de passos para a execução da estratégia. Detalha-se o papel de cada componente na estrutura hierárquica utilizada, ressaltando-se a opção por utilizar uma subcamada de ajuste de *setpoints* para fazer o interfaceamento entre as camadas *RTO* e *MPC*.

É apresentado ainda de que forma a opção pelo uso de modelos continuamente identificados é implementada na estratégia.

A seguir, nos capítulos 4 e 5 a estratégia é aplicada em dois processos químicos diferentes, o processo de *Otto*, e uma reação isotérmica. Nas duas implementações, os processos são submetidos a ensaios para demonstrar os ganhos obtidos com a utilização da estratégia proposta, principalmente quando comparados com a utilização padrão *RTO+MPC*. Os resultados obtidos mostram melhorias e manutenção da estabilidade dos processos controlados.

No capítulo 6 estão apresentadas as discussões provenientes da análise das simulações efetuadas nos dois processos diferentes, apresentando as conclusões finais e as perspectivas de continuação do presente trabalho.

Por fim, no Apêndice A estão apresentadas as equações diferenciais que modelam o balanço de energia e de massa da reação de Otto, cujos valores dos parâmetros podem ser obtidos no artigo (WILLIAMS; OTTO, 1960).

2 FUNDAMENTAÇÃO TEÓRICA

CONTROLE HIERÁRQUICO

“From a process engineering point of view, the purpose of automatic feedback control (and that of manual control as well) is not primarily to keep the controlled variables at their set-points as well as possible or to nicely track dynamic set-point changes, but to operate the plant such that the net return is maximized in the presence of disturbances and uncertainties, exploiting the available measurements.”

Engell (2007)

No presente capítulo é feita uma apresentação do problema que foi tratado, introduzindo conceitos básicos de teoria de controle e alguns conceitos envolvidos no controle de processos químicos, avançando até atingir a estruturação de sistemas complexos de controle, em uma hierarquia de camadas contendo otimizadores, controles avançados e controladores locais. Apresenta-se a revisão bibliográfica feita sobre o assunto para que se possa situar o trabalho proposto dentro da literatura relacionada ao tema. A apresentação dos problemas tratados em cada camada, e dos problemas envolvidos nas interações entre camadas auxilia no entendimento dos fundamentos da proposta apresentada em capítulos posteriores.

2.1 FUNDAMENTAÇÃO TEÓRICA

A área de controle e automação vem desempenhando um papel importante na evolução das engenharias, seja fazendo parte de processos de manufatura modernos quanto de processos contínuos industriais. Os avanços nesta área proporcionam meios para levar esses processos a obterem desempenhos ótimos (OGATA, 2001).

Em termos mais simples, o ato de controlar pode ser pensado como uma maneira de influenciar um objeto de maneira que este apresente um comportamento desejado (FINDEISEN et al., 1980). Uma estrutura de controle simplificada aplicada a um sistema qualquer é apresentada na figura 2.1. São elementos importantes desta estrutura: as entradas manipuladas m ; as perturbações z , que são sinais indesejáveis que afetam o comportamento do sistema; as saídas do sistema y ; e as variáveis observadas ou medidas v , que podem ser todas as saídas do sistema, parte delas, ou ainda variáveis que não podem ser medidas mas que podem ser estimadas a partir de outras informações do sistema.

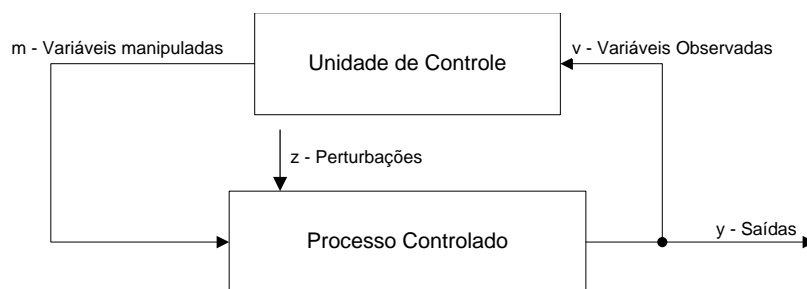



Figura 2.1: Estrutura de Controle Simplificado

De maneira bem resumida, pode-se dizer que a tarefa da unidade de controle é determinar, através dos cálculos apropriados, quais são os valores de m que levarão as saídas y a atingirem determinado objetivo, ainda que existam perturbações z .

Em um processo em escala industrial é comum haver mais do que uma dessas

estruturas de controle atuando de maneira interdependente. Para ilustrar este cenário, apresenta-se a seguir uma coluna de destilação binária comum, como a da figura 2.2, que pode ser decomposta para fins de controle em três subestruturas principais. A coluna propriamente dita, o Refervedor e o Condensador. Cada uma dessas estruturas apresenta suas dinâmicas e restrições próprias.

Figura 2.2: Típica Coluna de Destilação Binária



Fonte: (SKOGESTAD, 2000)

O Refervedor, que se localiza na base da coluna, adiciona calor a uma fração do destilado que se encontra ali, e que posteriormente retorna à coluna em forma de vapor. O Condensador, que se localiza no topo da coluna, retira calor do vapor que escapa pelo topo da coluna, condensando-o, e retornando parte deste para a coluna. E, por fim, a coluna que é onde acontecem as interações entre líquido e vapor, proporcionando a separação dos componentes mais pesados dos mais leves, que é o objetivo final da coluna. Em geral, existe uma estrutura de controle no Refervedor (geralmente controla-se o nível de líquido da base), uma no Condensador (geralmente controla-se o nível de condensado no tanque) e uma na Coluna, seja na vazão da alimentação, ou na pressão da coluna. Tendo em vista estas possibilidades de atuação no sistema, a operação da coluna deve conseguir responder às seguintes perguntas: Como obter o produto desejado, com a qualidade desejada, e nas quantidades desejadas da melhor forma possível? Como manter segura a operação do sistema? Como aumentar o retorno econômico?

Para conseguir obter uma operação adequada da coluna pode-se estabelecer diferentes estratégias para o seu controle. Por exemplo, é comum controlar a qualidade do destilado

através da atuação simultânea nas malhas de controle do Refervedor e do Condensador. Para todas as estratégias possíveis, há que se considerar que apesar das malhas de controle serem independentes, todas estão interconectadas pelas dinâmicas próprias das transferências de massa e energia. Por exemplo, um aumento da vazão do Refervedor implica em alterações na base da coluna que acabam se propagando pela coluna inteira, afetando de alguma maneira as outras malhas de controle. Estas questões são tratadas em (SKOGESTAD, 2000), onde é apresentado um estudo sobre estratégias de controle para uma coluna binária, aonde procura-se determinar quais, dentre as variáveis disponíveis conforme o grau de liberdade, são as melhores escolhas para serem efetivadas como variáveis manipuladas para obter o controle da coluna.

Outro problema menos relacionado à estrutura de controle e mais ligado aos controladores propriamente ditos, e que está sempre presente, é o ajuste fino dos parâmetros dos controladores. A sintonia dos diversos controladores *PID's* (*Proporcional-Integral-Derivativo*) em plantas industriais complexas constitui um desafio aos engenheiros de processo e operadores (ARRUDA et al., 2008). Nestas instalações, é comum a existência de processos multivariáveis que possuem variáveis com fortes interações entre si, além de não linearidades e de objetivos de controle conflitantes. Se para o problema da coluna binária, a escolha da estratégia de controle não é trivial, para um processo industrial complexo ela é ainda mais difícil.

Também fica em aberto a questão de, não obstante o sistema de controle buscar atender às especificações impostas, de que maneira se determina quais são as especificações? No caso específico apresentado, a coluna busca produzir uma quantidade determinada de um produto com algum nível de pureza mas a escolha de qual produto será produzido, a determinação da quantidade a ser produzida, e a determinação do percentual de destilação são assumidas como previamente conhecidas. Na realidade, as especificações são impostas ao sistema de controle como consequência indireta das relações de mercado do momento. Em um mercado dinâmico global, o fornecimento de matérias-primas por diferentes fornecedores aliados à demanda dos diferentes consumidores por produtos específicos, implicam em cenários de produção que estão constantemente se alterando, fazendo com que seja necessário alterar rapidamente as especificações em resposta ao mercado.

Além disso, pensando no processo produtivo em escala industrial, há que se considerar que várias unidades estão presentes na planta industrial. Utilizando o exemplo de uma refinaria de petróleo, além do processo de destilação, há uma sequência de processos ocorrendo ao mesmo tempo, como por exemplo: pré-aquecimento, destilação a vácuo, craqueamento térmico ou catalítico, e reforma catalítica. Para além do problema das estratégias de controle de cada unidade, haverá também o problema das possíveis interações e realimentações entre os

processos dessas unidades. Destas interações surgem problemas de agendamento e estocagem que também não são tratados pela estratégia de controle local.

Para tratar de maneira integrada todas as questões relacionadas com aspectos econômicos, gerenciais, de planejamento e de produção, tem-se tornado uma prática crescente estruturar as tomadas de decisão em uma planta industrial em uma hierarquia composta por cinco camadas. A estrutura será detalhada na seção 2.1.1.

2.1.1 ESTRUTURA HIERÁRQUICA DE CONTROLE

A estrutura hierárquica de controle está apresentada em detalhes na figura 2.3. A idéia principal que norteia sua elaboração é a decomposição da tarefa de controle original em uma sequencia de sub-tarefas mais simples e hierarquicamente estruturadas, tendo uma camada dedicada para tratar de cada sub-tarefa.

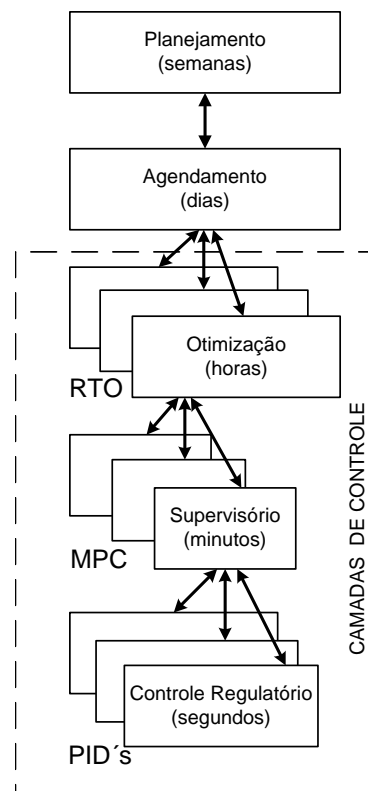


Figura 2.3: Hierarquia de Controle

Na primeira camada, *Planejamento*, as decisões tratam sobre quais matérias-primas comprar, qual a quantidade e o que produzir, ou seja, metas de produção para a unidade industrial inteira. Nela trabalha-se com um horizonte longo, em torno de semanas a meses, com estimativas de demanda e oferta. Estas decisões levam em consideração a situação econômica da empresa, e a situação do mercado em que está inserida, os custos envolvidos com a produção,

e preços de revenda do material produzido. Esta camada se relaciona às decisões da direção.

A segunda camada, *Agendamento*, recebe as metas de produção provenientes da primeira camada e trata de calcular a alocação de recursos, a organização espacial e temporal das matérias-primas e dos recursos dentro do espaço da empresa, evitando possíveis problemas de transferência e estocagem, a fim de que a meta seja atingida. Trabalha-se nesta camada com subintervalos da camada anterior, ou seja, um período que pode ir de alguns dias a uma semana, havendo a cada período a possibilidade de realocar os recursos para que a meta final seja atingida.

Estas duas primeiras camadas tratam de um problema mais amplo, relacionado às questões gerenciais que envolvam a otimização de toda a planta industrial. As camadas inferiores tratam de problemas mais locais, relacionados às questões operacionais. No meio da estrutura, a terceira camada, *Otimização*, é a que proporciona uma ligação entre as camadas gerenciais e as camadas inferiores que compõem o sistema de controle.

A camada de *Otimização* recebe da camada anterior a cota de produção diária e realiza cálculos para determinar qual seria o ponto de operação ótimo para aquela planta, e por isso essa camada também é denominada de camada de *Otimização Local*. Para tanto, analisa-se o estado atual da planta (variáveis, energia, ponto de operação), se há alterações no material recebido de plantas anteriores da unidade industrial, se há desgaste relevante nos equipamentos envolvidos na planta em que está inserida, se há por exemplo, desativação do catalisador ou se há acúmulo de fuligem, etc. Trabalha-se nesta camada com subintervalos da ordem de horas, e a cada novo instante de amostragem o cálculo é refeito.

A quarta camada, de controle supervisão (onde se encontra o *MPC*), recebe da camada anterior o ponto de operação ótimo e trata de conduzir a planta até este ponto da melhor forma possível. Caso o ponto de operação ótimo não se altere, esta camada rejeita as perturbações e mantém o sistema no mesmo ponto, determinando quais devem ser os valores dos conjuntos de variáveis controladas. Trabalha-se nesta camada com intervalos da ordem de minutos.

Por fim, a quinta camada, *Controle Local*, recebe os valores desejados para as variáveis controladas e trata de garantir que estas se mantenham nestes valores. Esta camada é tipicamente composta por *PID*'s dispostos em malha fechada. Trabalha-se nesta camada com intervalos da ordem de segundos.

É interessante perceber algumas características desta estrutura: ela distribui as tomadas de decisão ao longo das camadas, aonde cada camada executa uma tarefa específica; existe

um fluxo de informações entre camadas; os tempos de operação são distintos, bem como as responsabilidades e abrangências de cada camada. Esta estrutura tem sido amplamente adotada na indústria, especialmente na indústria de processos contínuos, e é a base dos processos e práticas em automação industrial.

Na seção seguinte, é feita uma revisão bibliográfica de trabalhos que relacionam otimização de processos industriais com sistemas de controle.

2.2 REVISÃO BIBLIOGRÁFICA

A otimização de processos industriais é uma área que tem recebido muita atenção há pelo menos três décadas. Em seus primórdios, antes da disponibilidade de recursos de hardware e software poderosos capazes de atuar em um ambiente multivariável e com requisitos de tempo-real, a otimização era feita na fase de projeto das instalações através do dimensionamento dos equipamentos, visando o uso extensivo dos mesmos quando de sua operação. De fato, a literatura da área de otimização no início da década de 80 apresentava, conforme relatado em (CUTLER; PERRY, 1983), muitos trabalhos focados na fase de projetos de plantas de processos químicos.

Entretanto, o aumento incessante da competição em nível global, a demanda por produtos de maior qualidade, e a pressão cada vez mais intensa por corte de custos são fatores que pressionam as empresas a utilizarem sistemas de produção dinâmicos e flexíveis - como por exemplo os sistemas de produção *just-in-time* - e a se integrarem rapidamente em cadeias de suprimento (FORBES; MARLIN, 1996). Em cenários dinâmicos assim, a otimização *offline* perde espaço para as estruturas de controle dinâmicas que sejam capazes de melhorar rapidamente o resultado econômico das plantas controladas.

Em termos mais específicos sobre a disposição de sistemas de controle dentro de uma estrutura de controle hierárquico, encontram-se na literatura alguns trabalhos através dos quais é possível compreender um pouco melhor as características dessa estrutura. Em (FINDEISEN et al., 1980), os autores realizam um trabalho matematicamente rigoroso direcionado a controles de processos químicos, em que investiga-se como fazer a coordenação das atividades entre as três camadas inferiores através de ferramentas de otimização matemática. Mclean et al. (1986) apresentam uma proposta de controle hierárquico para sistemas automatizados de manufatura, que tem a capacidade de lidar com imprevistos cotidianos sem que haja necessidade de intervenção por parte dos operadores. Ainda com o enfoque nestes sistemas, WU e WYSK (1991) apresentam um estudo mais detalhado sobre as

camadas de planejamento e otimização. Por fim, no capítulo 11 do livro (LIPTAK et al., 2005), os autores apresentam a evolução do controle hierárquico, do ponto de vista do *hardware* que o compõe, desde a época dos sistemas analógicos até os modernos sistemas digitais e informatizados de controle.

Uma das primeiras e possíveis abordagens de desenvolvimento de uma estrutura de controle dinâmica é aquela conhecida como otimização por regulação, ou controle auto-otimizável (*Self-optimizing control*). Nesta abordagem, considera-se que em muitos casos a magnitude das perturbações não são significativas, e desta forma, a alteração econômica que resulta da reotimização dos *setpoints* é comparável às que resultam por manter o sistema fixo no mesmo ponto de operação desprezando as perturbações. Sendo assim, estuda-se dentro do conjunto das variáveis controláveis as suas relações com o resultado econômico da planta, e escolhe-se então, dentro do conjunto, aquelas que manterão o resultado econômico menos alterado quando mantidas fixas em *setpoints* apropriados. É uma abordagem direcionada à escolha da estrutura de controle tendo uma forte orientação econômica, mas que entretanto, peca por apresentar uma flexibilidade reduzida pois quando ocorrem perturbações de magnitude maior, o sistema não consegue se ajustar e proporcionar resultados econômicos melhores. Maiores informações podem ser obtidas no trabalhos apresentados em (MORARI et al., 1980), (SKOGSTAD, 2000) e (ENGELL, 2007).

Na década de 80, o desenvolvimento da área de controle de processos concomitante à disponibilidade de recursos de informática cada vez mais poderosos, propiciou, pela primeira vez, o surgimento da otimização em tempo real utilizando um rigoroso modelo estacionário do processo. Já no início da década, Cutler e Perry (1983) defendiam a aplicação desta abordagem para conseguir melhorar o resultado econômico das plantas controladas.

A aplicação de modelos rigorosos nos *RTO* se tornou viável após o surgimento do recurso computacional de modelagem em equações abertas (*open-equation modeling*), através do qual o usuário se abstrai de questões internas como tamanho do passo de simulação, critérios de convergência do algoritmo, etc., direcionando o foco do usuário às equações propriamente ditas do modelo. Para ilustrar a capacidade dos recursos disponíveis, em 2011 era possível utilizar modelos com um número entre 100.00 a 200.000 equações, envolvendo 30 a 40 variáveis de decisão (DARBY et al., 2011).

Como o ponto de operação obtido ao final de cada iteração do *RTO* reside, de maneira geral, na intersecção entre algumas das restrições do problema, torna-se necessário utilizar algum sistema de controle adequado, que seja capaz de tratar destas restrições e ao mesmo tempo rejeitar perturbações ou direcionar o processo, quando for o caso, de

modo a alcançar estes pontos de operação (CUTLER; PERRY, 1983). A possibilidade de utilização dos controladores *MPC*, já no final da década de 70, que traziam consigo conceitos novos como o uso de modelos do processo na previsão do comportamento futuro, o recálculo das ações futuras dentro dos horizontes de predição a cada instante de amostragem, otimização de índices de desempenho com a inclusão das restrições nos cálculos, dentre outros, criou novas possibilidades de abordagem dos problemas de controle existentes, dentre as quais, por exemplo, a sua aplicação junto aos *RTO*. Exemplos clássicos de *MPC*'s são apresentados em (RICHALET et al., 1978),(CUTLER; RAMAKER, 1979), (DEKEYSER; CAUWENBERGHE, 1985), e (CLARKE et al., 1987b). Para uma visão mais aprofundada sobre estes controladores, os dois artigos apresentados a seguir merecem ser destacados. Em (RAWLINGS, 2000) o autor apresenta um tutorial muito interessante sobre *MPC*'s, abrangendo tipos de modelos, restrições e questões de otimização. Em (DARBY; NIKOLAOU, 2012), é possível obter referências um pouco mais recentes de utilização com sucesso de *MPC*'s em diferentes áreas, como por exemplo em processos de refino, em plantas de processamento de papel, ou em engenharia aeroespacial.

A forma como é feita a coordenação entre os resultados obtidos pelo *RTO* e o controle supervísório efetuado pelo *MPC* é objeto de estudo de diversos autores. Um bom ponto de partida para os estudos nesta área está apresentado em (DARBY et al., 2011), aonde os autores fazem uma revisão sobre o controle hierárquico em camadas, comentando sobre as dificuldades que surgem na integração das camadas, e trazendo exemplos de abordagens diferentes que têm sido usadas para implementar camadas *RTO* em conjunto com *MPC*. Na conclusão do mesmo artigo, estão colocadas algumas possibilidades de desenvolvimento futuras que inspiram em parte o desenvolvimento deste estudo.

Um trabalho não tão atual, mas que merece ser lembrado por sua contribuição para o entendimento da estrutura hierárquica e das alternativas de implementação, está apresentado em (TATJEWSKI, 2008). Neste artigo apresentam-se diferentes possibilidades de implementação da otimização dos processos, seja de forma dinâmica ou estacionária, e de como é feita a interface da camada de otimização com os controladores *MPC*.

Em (CHACHUAT et al., 2009), os autores apresentam três estratégias diferentes para implementar características de adaptação na camada *RTO* de um sistema de controle hierárquico. Na primeira, este objetivo é alcançado através do ajuste de parâmetros do modelo a partir de informações do estado do sistema; na segunda, através da alteração dos valores limite das restrições ou dos gradientes dos problemas de otimização; e na terceira, através do problema de seguimento de referências de variáveis controladas apropriadas. Este artigo traz informações

importantes sobre como garantir que a adaptação do modelo do processo usado na camada *RTO* não cause uma perda de rastreabilidade do ponto ótimo da planta real.

Em (ALVAREZ; ODLOAK, 2010), apresenta-se outro trabalho interessante no qual trata-se da integração robusta entre as camadas *RTO* e *MPC*, utilizando uma subcamada intermediária conhecida por *SSTO* (*Steady-State Target Optimization*). Filtra-se em primeiro lugar os *setpoints* determinados pela camada *RTO*, através da camada intermediária, de maneira a garantir que estes serão alcançáveis pela camada *MPC*. Em seguida, garante-se que a camada inferior atingirá estes *setpoints* em um horizonte infinito através do ajuste de uma variável de relaxamento. Neste trabalho, aparece o problema do desempenho inferior ou instável do controlador *MPC* quando o sistema está muito distante do ponto de operação desejado, problema este que é contornado utilizando uma estratégia multi-modelos. Dentro de um conjunto discreto de modelos, escolhe-se o que traz melhor resultado, garantindo um desempenho bom do sistema de controle em uma grande faixa de excursão. A perda de desempenho quando o sistema está distante do ponto de linearização do modelo é um problema ressaltado no artigo mencionado e que motiva o uso de modelos continuamente identificados na proposta desenvolvida nesta tese.

Um segundo trabalho que traz mais informações sobre adaptação, agora aplicada na subcamada intermediária *SSTO*, está apresentado em (SHEAD et al., 2009). Neste trabalho, os autores investigam quais condições são necessárias (quando utiliza-se estratégias adaptativas) para que o sistema não perca a capacidade de seguir referências. Três abordagens utilizadas para superar problemas decorrentes do uso de modelos com incerteza são mencionadas, a saber: *Model-adaption*, no qual os parâmetros do modelo são ajustados de forma que ele represente adequadamente o sistema; *Modifier-adaptation*, no qual ajustes são feitos na própria função objetivo utilizada na otimização; e *Direct-input-adaptation*, que é a utilização da estratégia *Self-Optimizing Control Structure*.

No início desta década, no trabalho apresentado por Souza et al. (2010) está colocada uma integração de camadas com um aspecto econômico, na qual a camada *MPC* é modificada pela inclusão de um termo, relacionado ao gradiente econômico, no índice do controlador preditivo. Desta forma, é possível fazer com que as ações de controle futuras sejam escolhidas já levando em consideração em seus cálculos as respectivas consequências econômicas. Mantém-se o modelo linear do sistema e a solução do problema desta camada através de uma ferramenta de programação quadrática. Como desvantagem, há mais uma variável para ajustar na sintonia deste *MPC*, e o sistema não garante desempenho econômico melhor nos pontos distantes do ponto de linearização do modelo.

Uma abordagem adaptativa na camada *SSTO* é apresentada em (ŁAWRYŃCZUK, 2011) aplicada a um controle de fermentação de levedura. Neste trabalho, faz-se uso de redes neurais que são linearizadas *online* para modelar o sistema nas camadas inferiores, *SSTO* e *MPC*. Os autores argumentam que as redes neurais têm a capacidade de mimetizar a relação dos sinais entrada x saída de maneira bastante precisa, se aproximando bastante das respostas do sistema. Desta forma, é possível tratar as otimizações das respectivas camadas com programação linear ou quadrática. Esta abordagem conseguiu resultados similares aos obtidos em uma abordagem alternativa baseada em controlador não linear *NMPC*, com redução significativa de esforço computacional.

Marchetti et al. (2014) apresentaram os resultados de suas investigações em que tratam do mesmo problema de integração entre as camadas *RTO* e *MPC* através de uma camada intermediária. Neste trabalho em particular, as informações contidas em dados adicionais provenientes da camada *RTO* (como os gradientes, o Hessiano e o conhecimento das restrições ativas), foram usadas para aprimorar o desempenho da camada intermediária, o que pode ser observado nos resultados apresentados.

Além das abordagens baseadas na divisão em duas camadas, ou inclusão de uma subcamada, há também trabalhos feitos baseados na fusão das camadas em uma única camada de otimização e controle, conhecida como Controle Ótimo Direto em Linha (*Direct Online Optimizing Control*). Nesta abordagem, as três camadas inferiores, *RTO*, *Supervisório* e *Controle Regulatório*, são fundidas em uma só, o que exige uma combinação de *hardware* e *software* com grande capacidade de processamento. Trata-se de utilizar diretamente os graus de liberdade do processo para otimizar um índice que inclua aspectos econômicos, dentro de um horizonte de predição, e baseado em um modelo não linear, dinâmico, e abrangente da planta. Trabalhos que envolvam controladores *NMPC*, (ou *Nonlinear Model Predictive Control*, também conhecidos como *NLMPC*), se encaixam nesta abordagem, dentre os quais alguns bons exemplos são os trabalhos apresentados em (SINGH et al., 2000), (JOHANSEN; SBARBARO, 2005) e (BARTUSIAK, 2007).

Em outro trabalho nesta mesma abordagem apresentado em (GOPALAKRISHNAN; BIEGLER, 2013), os autores fundem as camadas *RTO* e *MPC* em um controlador não linear *NMPC*, utilizado na otimização dos custos operacionais de uma rede de gasodutos. O índice de otimização deste controlador é o próprio custo de operação do sistema, e o problema de otimização é resolvido por uma ferramenta de otimização de problemas do tipo *NLP*. As restrições de terminalidade são adequadamente ajustadas para garantir estabilidade e convergência assintótica da solução.

No trabalho apresentado em (REVOLLAR et al., 2015), os autores efetuam o controle de um processo de tratamento de água, através de uma estrutura de camada única na qual integra-se um modelo não linear do processo com os cálculos econômicos. Por ser um processo não linear com muita variação na alimentação e nas perturbações, com grande faixa de operação, os autores alegam que o uso das camadas *RTO* e *MPC* em separado não proporcionaria um desempenho adequado (esta é a mesma razão pela qual o presente trabalho sugere o uso das três camadas, porém com o uso de modelos continuamente identificados). Ao longo do trabalho a proposta tem seu desempenho comparado àqueles obtidos com o uso de controladores *PI* e com um controlador *NMPC*, tendo como resultado um desempenho econômico superior, ainda que ao custo da ocorrência de um pequeno aumento da concentração de nitrogênio nos efluentes.

As muitas idéias contidas nesses trabalhos contribuíram para a formulação da proposta desta tese. Muitos conceitos relacionados ao controle hierárquico, integração das camadas e possíveis implicações na estabilidade e robustez do sistema controlado, foram melhor assimilados após a leitura desses trabalhos.

A estratégia de integração proposta nesta tese, inspirada pelas possibilidades de desenvolvimento apresentados em (DARBY et al., 2011), configura-se dentro de uma estrutura hierárquica de controle tal qual apresentado anteriormente em diversos trabalhos. Para mediar as trocas de informações entre a camada de *Otimização* e *Supervisório*, decidiu-se pela inclusão de uma subcamada intermediária *SSTO*, de maneira similar ao apresentado em (ALVAREZ; ODLOAK, 2010; ŁAWRYŃCZUK, 2011; SHEAD et al., 2009). Adicionalmente, tendo em vista a possibilidade de operar em pontos de operação imprevistos como resultado das ações do *RTO*, e buscando evitar a perda de desempenho que ocorre quando a representatividade do modelo é diminuída, situação apontada em (ALVAREZ; ODLOAK, 2010; SOUZA et al., 2010; REVOLLAR et al., 2015), e ainda, tendo por objetivo não perder flexibilidade como o que acontece na estrutura proposta em (SKOGESTAD, 2000; ENGELL, 2007), optou-se pelo uso de modelos lineares continuamente identificáveis na camada *SSTO+MPC*. Importante mencionar também que a integração proposta utiliza recursos difundidos e bem aceitos em ambiente industrial, como por exemplo, o uso de controladores preditivos, integração de sistemas de controle em redes informatizadas, uso de modelos lineares, etc. Desta forma a estratégia proposta concilia as características de rastreamento ativo do ponto de ótimo econômico, harmonização das camadas, representatividade dos modelos utilizados e implementação facilitada em ambiente industrial.

Para melhor entender as três camadas inferiores da estrutura, que são as camadas relevantes para o trabalho desenvolvido no doutorado e apresentado na presente tese, elas serão

vistas com maior profundidade na seção 2.2.1.

2.2.1 OTIMIZAÇÃO E CONTROLE DE PLANTAS

Há pelo menos 10 anos, a utilização de algoritmos de otimização em tempo real (*RTO*) na camada de Otimização tem se tornado mais frequente na indústria, por causa do custo decrescente e da maior disponibilidade de recursos de *software* e de *hardware*. A importância desta camada na indústria química pode ser percebida em vários artigos (YING; JOSEPH, 1999; BACKX et al., 2000; FRIEDMAN, 2000; TATJEWSKI et al., 2006; TATJEWSKI, 2008; CHACHUAT et al., 2009; MARCHETTI et al., 2014; FERRAMOSCA et al., 2017). O uso de *RTO* na camada de *Otimização* se torna interessante pela flexibilidade que este proporciona ao sistema controlado, ou seja, pela sua capacidade de fazer o sistema controlado rastrear o ponto de ótimo econômico mesmo quando surjam perturbações na alimentação dos processos, alterações do ambiente econômico, desgaste do equipamento, etc. Na figura 2.4 apresentam-se os blocos internos que compõem a sequência de operações que ocorre no *RTO*.

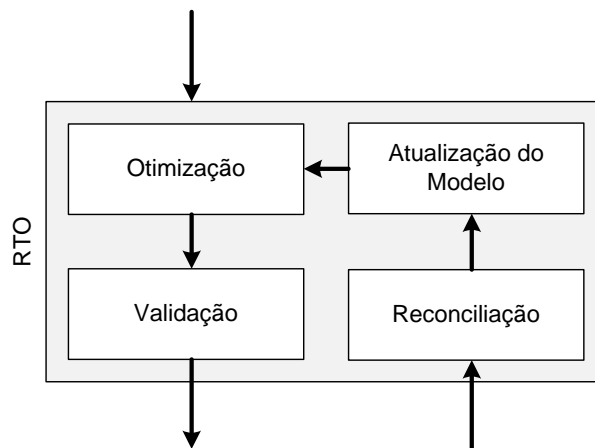


Figura 2.4: Estrutura detalhada de um sistema *RTO*

Os dados da planta são enviados para o *RTO* onde avalia-se se um estado estacionário foi atingido. Caso positivo, estes dados são enviados para o bloco *Reconciliação* onde serão reconciliados com equações de balanço de massa e energia, para minimizar possíveis erros de instrumentação, e assim detectar com maior precisão o ponto de operação real da planta. Os dados reconciliados são então utilizados na atualização dos parâmetros do modelo. A seguir, o modelo atualizado é utilizado pelo otimizador no processo de rastreamento do ponto de operação ótimo. Ao final deste processo, obtém-se um candidato a ponto de operação ótimo a ser enviado às camadas de controle. Entretanto, antes de passar o ponto de operação para as camadas de controle, ele é analisado no bloco de *validação* para verificar se os seus valores são plausíveis, se devem ser limitados para evitar desgaste nos atuadores, etc.

O ponto de operação da planta se traduz em alguns valores de *setpoints* para um conjunto de variáveis controladas. Esta informação é passada às camadas inferiores, que então atuam nos graus de liberdade da planta, de maneira a manter as variáveis controladas o mais próximo possível dos seus respectivos *setpoints*.

Para apresentar o problema de otimização matemático resolvido na camada de Otimização, utiliza-se a notação apresentada anteriormente em (MARCHETTI et al., 2014), onde o modelo estacionário que representa a planta está apresentado nas equações 2.1a e 2.1b,

$$f(x, u, \theta) = 0 \quad (2.1a)$$

$$y = \mathcal{F}(x, \theta) \quad (2.1b)$$

onde $x \in \mathbb{R}^{n_x}$ são as variáveis de estado do modelo, $u \in \mathbb{R}^{n_u}$ representa as entradas do processo, $\theta \in \mathbb{R}^{n_\theta}$ é o conjunto dos parâmetros do modelo, e $y \in \mathbb{R}^{n_y}$ representa as saídas do processo.

No presente estudo, considera-se que o modelo utilizado pelo *RTO* representa suficientemente bem a planta controlada, de modo que as questões relacionadas à falta de representatividade do modelo em relação ao processo real são desconsideradas, assim como não são utilizadas estratégias de adaptação na camada de Otimização. Para além deste ponto, sem prejuízo em relação aos objetivos propostos, considera-se no estudo presente que a camada de Otimização se restringe à busca pelo ponto ótimo de operação que é efetuado pela ferramenta de otimização. No presente trabalho utilizou-se da função *fmincon*, pertencente ao pacote matemático *Matlab*[®]. O problema de otimização resolvido pelo *RTO* está apresentado na equação 2.2.

$$\begin{aligned} u_{RTO} &= \underset{u}{\operatorname{argmin}} \phi(u, y(u, \theta)) \\ \text{s.a.} \\ y^{eq}(u, \theta) &= y^S \\ y^L &\leq y^{in}(u, \theta) \leq y^U \\ u^L &\leq u \leq u^U. \end{aligned} \quad (2.2)$$

onde $\phi : \mathbb{R}^{n_u} \times \mathbb{R}^{n_y} \rightarrow \mathbb{R}$ é a função econômica a ser minimizada, $y(u, \theta)$ representa o mapeamento de entrada-saída que é obtido através da solução da equação 2.1a, seguido da obtenção de y através da equação 2.1b; $y^{eq} \in \mathbb{R}^{n_y^{eq}}$ é o conjunto de saídas com restrições de igualdade para as quais y^S são os valores de *setpoint*; $y^{in} \in \mathbb{R}^{n_y^{in}}$ é o conjunto de restrições de desigualdade para as quais y^L e y^U correspondem respectivamente aos valores inferiores e

superiores; e u^L e u^U correspondem respectivamente aos valores inferiores e superiores nas variáveis de decisão. O conjunto das saídas com restrições, y^{eq} e y^{in} , são subconjuntos do conjunto de saídas do sistema y .

Resumidamente, este é um problema de programação não-linear que após a convergência do algoritmo, produz como resultado os valores de u_{RTO} e y_{RTO} , sujeitos às restrições de valor inferior e superior, que correspondem ao ponto de operação de melhor resultado econômico. A relação entre u_{RTO} e y_{RTO} é dada pelo modelo do sistema, apresentado nas equações 2.1a e 2.1b. O conjunto de valores que constituem o ponto de operação (u_{RTO}, y_{RTO}) é repassado às camadas inferiores, para que estas conduzam a planta a este ponto de operação, ou seja, para que seja direcionada em busca de melhorar o rendimento econômico. Entretanto, de que forma este resultado é recebido pelas camadas inferiores? De que forma acontece a interação entre os níveis tático e operacional da estrutura hierárquica? Esta é a questão que pretende ser respondida na subseção 2.2.2.

2.2.2 INTEGRAÇÃO ENTRE *RTO* E *MPC*

A integração entre o *RTO* e o *MPC* não se obtém de maneira trivial, devido às diferenças entre os modelos utilizados em cada camada, e às questões relacionadas à estacionariedade (BACKX et al., 2000; SEQUEIRA et al., 2002). Para auxiliar na compreensão dos problemas envolvidos, apresentam-se a seguir as características do controlador preditivo adotado. Cabe mencionar que apesar do estudo tratar das questões que surgem em decorrência da integração do *RTO* com qualquer abordagem de controlador preditivo *MPC*, a opção por uma abordagem específica de controlador preditivo nesta seção, não altera a generalidade dos problemas apresentados aqui.

Neste estudo, optou-se pela implementação do controlador preditivo do tipo *GPC* (*Generalized Predictive Control*). Este controlador foi desenvolvido para ser um controlador genérico (origem de sua denominação), aplicável à maioria dos tipos de processos industriais, como processos de fase não-mínima, processos instáveis em malha aberta, processos com atraso desconhecido ou variável e processos de ordem desconhecida (CLARKE et al., 1987a; CLARKE et al., 1987b). Uma característica bastante útil desta abordagem é que seus cálculos não se baseiam em modelos obtidos através da resposta ao degrau, mas ao invés disso, em modelos lineares do tipo função de transferência, que são modelos para os quais o processo de identificação de parâmetros é de fácil implementação. O uso de modelos lineares tem se mostrado adequado em muitos problemas de controle encontrados nos processos industriais (GATTU et al., 2003), mesmo quando confrontados com as novidades da área de controle não

linear. Neste sentido, Darby e Nikolaou (2012) reforçam que mesmo com o desenvolvimento contínuo das técnicas de controle baseadas em modelos não lineares, o uso de controladores preditivos baseados em modelos lineares ainda representa a maioria das aplicações industriais.

Desta forma, tendo em vista que o escopo principal deste trabalho se situa nas interações existentes dentro de uma estrutura hierárquica de controle (uma estrutura padrão da área industrial), a aptidão da abordagem *GPC* aos diferentes processos industriais, a facilidade de sua utilização combinada com técnicas de identificação, bem como sua difusão e aceitação em ambiente industrial justificam a escolha no presente trabalho por esta abordagem de controlador preditivo.

A abordagem *GPC* utiliza modelos conhecidos como *CARIMA* (*Controlled Autoregressive Integrated Moving Average*). A versão *CARIMA* multivariável utilizada nesta tese está apresentada na equação 2.3.

$$A(z^{-1})y(t) = z^{-d}B(z^{-1})u(t-1) + I_{n_y \times n_y} \cdot \frac{e(t)}{\Delta} \quad (2.3)$$

onde $u \in \mathbb{R}^{n_u \times 1}$ representa as entradas do processo, $y \in \mathbb{R}^{n_y \times 1}$ representa as saídas do processo, $\Delta = 1 - z^{-1}$, d representa o atraso do processo, $I \in \mathbb{R}^{n_y \times n_y}$ é a matriz identidade, $A \in \mathbb{R}^{n_y \times n_y}$ e $B \in \mathbb{R}^{n_y \times n_u}$ são polinômios matriciais em z :

$$\begin{aligned} A(z^{-1}) &= I + A_1 z^{-1} + A_2 z^{-2} + \dots + A_{n_a} z^{-n_a} \\ B(z^{-1}) &= B_0 + B_1 z^{-1} + B_2 z^{-2} + \dots + B_{n_b} z^{-n_b} \end{aligned}$$

O algoritmo do *GPC* busca a sequência de controle que minimiza a função de custo apresentada na equação 2.4.

$$J(N_1, N_2, N_u) = \sum_{j=N_1}^{N_2} \delta(j) [\hat{y}(t+j|t) - w(t+j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t+j-1)]^2 \quad (2.4)$$

onde N_1 e N_2 definem o horizonte de predição, N_u define o horizonte de controle, $w(t+j)$ é a trajetória de referência futura, $\delta(j)$ e $\lambda(j)$ são sequências de pesos adequados de ponderação, e $\hat{y}(t+j|t)$ é a predição ótima da saída do sistema j -passos à frente. Para obter $\hat{y}(t+j|t)$ faz-se uso da equação Diofantina 2.5.

$$1 = E_j(z^{-1})\Delta A(z^{-1}) + z^{-j}F_j(z^{-1}) \quad (2.5)$$

que pode ser reescrita como apresentado na equação 2.6.

$$1 - z^{-j}F_j(z^{-1}) = E_j(z^{-1})\Delta A(z^{-1}) \quad (2.6)$$

A equação 2.6 indica que é possível obter-se recursivamente os polinômios E_j e F_j através da divisão de 1 por $\Delta A(z^{-1})$, conforme apresentado em (CLARKE et al., 1987b). Obtém-se então $z^{-j}F_j(z^{-1})$ no resto da divisão, e $E_j(z^{-1})$ no quociente da divisão.

Multiplicando-se então a equação 2.3 por $\Delta E_j(z^{-1})z^j$, obtém-se a equação 2.7.

$$E_j(z^{-1})\Delta A(z^{-1})y(t+j) = E_j(z^{-1})B(z^{-1})\Delta u(t+j-d-1) + E_j(z^{-1})e(t+j) \quad (2.7)$$

Agora, considerando que a melhor predição para o erro no futuro é $e(t+j) = 0$, e considerando as equações 2.6 e 2.7, é possível obter uma equação para predição do comportamento do sistema no futuro como apresentado em 2.8. (Obs: O desenvolvimento completo desta solução matemática está descrito em detalhes em (CAMACHO; BORDONS, 1999)).

$$\hat{y}(t+j|t) = E_j(z^{-1})B(z^{-1})\Delta u(t+j-d-1) + F_j(z^{-1})y(t) \quad (2.8)$$

Comparando-se as equações 2.1a, e 2.1b do modelo utilizado pelo *RTO* com a equação 2.3 do modelo utilizada pelo *GPC*, fica claro que são modelos diferentes, e que para os quais não se pode garantir que produzam predições consistentes entre si, a não ser talvez quando o processo esteja operando nas proximidades do ponto de linearização, o que traz uma série de implicações para a integração *RTO+GPC*.

Considere por exemplo que A seja a matriz de ganho estacionário do modelo utilizado no *GPC*, de tal forma que $y = A \cdot u$, onde y e u correspondem respectivamente às saídas e entradas do sistema, sujeitos às restrições estabelecidas. É possível que a seguinte situação ocorra: um ponto de operação (u_{RTO}, y_{RTO}) é repassado pelo *RTO* ao *GPC* como *set-points* a serem buscados; entretanto o *GPC* não consegue encontrar, dentro das restrições estabelecidas, uma solução factível. Por exemplo, caso o ponto de operação (u_{RTO}, y_{RTO}) imposto ao *GPC* fosse tal que $y_{RTO} \neq A \cdot u_{RTO}$, para conseguir conduzir o sistema a este ponto de operação poderia ser necessário violar alguma das restrições. Pode acontecer ainda de y_{RTO} ou u_{RTO} imposto pelo *RTO* estar fora do espaço delimitado pelas restrições do *GPC*.

A interação entre predições baseadas em modelos diferentes nas duas camadas foi estudada em (YING; JOSEPH, 1999), onde também verifica-se o surgimento dos *offsets* quando a ocorrência de uma perturbação causa a ativação da restrição de alguma variável no *GPC*, diminuindo-se o grau de liberdade e impedindo o sistema de atingir o *setpoint* imposto pelo

RTO. A existência de *offsets* pode ser inaceitável em muitos casos, como por exemplo, quando as exigências de qualidade de um produto destilado são grandes. Em um cenário ideal deve-se buscar evitar estas situações, mas caso isto não seja possível, deve-se buscar harmonizar da melhor forma possível as inconsistências entre os modelos.

Além das diferenças entre modelos, Engell (2007) coloca como outro problema relevante da integração *RTO+GPC* o longo período de amostragem do *RTO*. Como aciona-se a camada *RTO* somente após a detecção de um novo ponto estacionário, esta pode ficar inativa por longos períodos de tempo. Em outras palavras, até que haja um novo acionamento, o rastreamento econômico efetuado pelo *RTO* estará suspenso, o ponto (u_{RTO}, y_{RTO}) não será atualizado, e possivelmente ocorrerão perdas econômicas. Há muitos casos na vida real de perturbações (que afetam o desempenho econômico) com dinâmicas similares às dinâmicas do próprio processo (TATJEWSKI, 2008), o que demanda do sistema hierárquico de controle a capacidade de lidar com elas de maneira apropriada. As perturbações econômicas de dinâmica lenta podem ser adequadamente tratadas pelos acionamentos regulares do *RTO*, mas as perturbações econômicas de dinâmica rápida não podem aguardar o próximo instante de amostragem do *RTO*, caso contrário corre-se o risco de incorrer em perdas econômicas. Ou seja, uma perturbação que afete o resultado econômico do sistema não será tratada até que a planta atinja a estacionariedade, e que o sistema a detecte.

E aqui entra o problema da detecção de estacionariedade. Apesar do conceito de estacionariedade ser simples, a detecção de um novo ponto estacionário não é uma tarefa fácil. Por exemplo, as variáveis do processo costumam variar dentro de uma faixa. Como saber se as leituras correspondem à flutuação natural das variáveis, ou seja se elas flutuam em torno de um ponto estacionário, ou se a variação está relacionada à transição entre pontos de operação distintos? Para adicionar dificuldade ao problema, as leituras são frequentemente corrompidas por falta de calibração e/ou mal funcionamento dos equipamentos, ou pela contaminação por ruídos. O problema da detecção de estacionariedade tem sido objeto de diferentes estudos como por exemplo (HOU et al., 2016), (JIANG et al., 2003), e (XIE et al., 2018).

Em resumo, um bom sistema de controle hierárquico deve ser capaz de minimizar as inconsistências entre os modelos utilizados nas diferentes camadas, bem como ter um período de amostragem adequado às dinâmicas das perturbações pertinentes. Estas questões devem estar presentes também na integração das camadas.

É possível obter a integração *RTO+GPC* por diferentes maneiras. Por exemplo, pode-se incluir um termo adicional $\| u - u_{RTO} \|_2$ na função objetivo utilizada pelo algoritmo *GPC*, conforme apresentado em (BROSILOW, 2002). Esta opção implica em redução do grau de

liberdade e pode resultar em *offsets* nas saídas do processo quando alguma restrição estiver ativa. Outras opções similares podem ser tentadas, mas em geral implicam em algum momento na diminuição dos graus de liberdade ou na distribuição de *offsets*.

A pesquisa nesta área tem se mostrado bastante ativa, como pode ser notado em trabalhos recentes como por exemplo (PETERSEN et al., 2017), (HINOJOSA et al., 2017) e (JAMALUDIN et al., 2017). Recentemente, uma edição especial do *Journal Processes* totalmente dedicada à integração de *RTO* dentro de estruturas hierárquicas de controle (BONVIN, 2017) foi lançada, trazendo um conjunto de artigos muito esclarecedores sobre o tema.

Uma alternativa que busca melhorar a integração dos sistemas *RTO+MPC* e tem sido utilizada em alguns trabalhos, consiste em incluir uma camada intermediária (ou sub-camada) acoplada à camada *MPC*, que é conhecida como *SSTO* (em português, Otimização de Alvos de Estado Estacionário). A seguir ela será descrita em maiores detalhes.

2.2.3 INCLUSÃO DE SUBCAMADA INTERMEDIÁRIA

Esta subcamada é executada com o mesmo período de amostragem que o *GPC*, e utiliza a versão estacionária de seu modelo. Adiciona-se esta subcamada para corrigir os *setpoints* (u_{RTO}, y_{RTO}) para alvos (u_{SSTO}, y_{SSTO}) que sejam alcançáveis pela camada *GPC*, que agora se torna uma subcamada. Assim sendo, a camada *Supervisório* é composta agora por duas subcamadas. Sua estrutura está apresentada na figura 2.5.

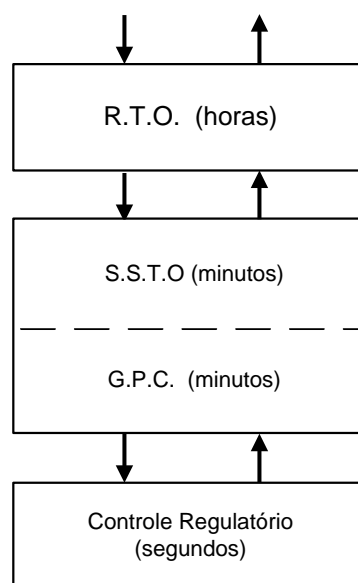


Figura 2.5: Estrutura *RTO-SSTO-GPC*

Inclui-se esta subcamada para obter na integração entre *RTO* e *MPC* melhorias como a

minimização da inconsistência que decorre do uso de modelos diferentes ao longo das camadas; aumento na velocidade de reposta da estrutura de controle às perturbações com impactos econômicos; o reforço da estabilidade do sistema através da suavização das mudanças de *setpoints*; um tratamento otimizado e mais adequado em relação aos *offsets* entre entradas/saídas e respectivos *setpoints*.

A subcamada *SSTO* pode ser implementada em duas abordagens distintas. Na primeira formulação, citada em (MARCHETTI et al., 2014; RAO; RAWLINGS, 1999), efetua-se uma busca de alvos alcançáveis em uma região de proximidade, no sentido quadrático, em torno de (u_{RTO}, y_{RTO}) , como apresentado na equação 2.9. É possível utilizar também um critério de distância linear, caso seja necessário, o que é facilmente obtido pela substituição dos termos $\|y_{SSTO} - y_{RTO}\|_{Q_s}^2$ por $q_s^T(y_{SSTO} - y_{RTO})$, e assim por diante.

$$\begin{aligned}
 & \min_{u_{SSTO}, y_{SSTO}} \|y_{SSTO} - y_{RTO}\|_{Q_s}^2 + \|u_{SSTO} - u_{RTO}\|_{R_s}^2 \\
 & \text{s.a.:} \\
 & y_{SSTO} = A_s u_{SSTO} + d(t|t) \\
 & y_{SSTO}^{eq} = y^S \\
 & y^L \leq y_{SSTO}^{in} \leq y^U \\
 & u^L \leq u_{SSTO} \leq u^U
 \end{aligned} \tag{2.9}$$

onde y_{RTO} e u_{RTO} são os *setpoints* determinados pelo *RTO*; y_{SSTO} e u_{SSTO} são os alvos ajustados pela subcamada *SSTO*; A_s é a matriz de ganhos estáticos e $d(t|t)$ é a perturbação. Tanto A_s quanto $d(t|t)$ são obtidos a partir do *GPC*, o que garante que os modelos dentro da camada sejam consistentes.

Na segunda abordagem, citada em (KASSMANN et al., 2000; ALVAREZ; ODLOAK, 2010; MARCHETTI et al., 2014), os *setpoints* (u_{SSTO}, y_{SSTO}) são ajustados a partir de uma nova otimização da mesma função econômica utilizada na camada *RTO*, porém utilizando como base a versão estática do modelo utilizado no *GPC* ao invés de utilizar o modelo não linear da camada *RTO*. Esta abordagem está apresentada na equação 2.10.

$$\begin{aligned}
u_{SSTO}, y_{SSTO} &= \underset{u, y}{\operatorname{argmin}} \phi(u, y) \\
\text{s.a.:} \\
y_{SSTO} &= A_s u_{SSTO} + d(t|t) \\
y_{SSTO}^{eq} &= y^S \\
y^L &\leq y_{SSTO}^{in} \leq y^U \\
u^L &\leq u_{SSTO} \leq u^U
\end{aligned} \tag{2.10}$$

onde y_{SSTO} e u_{SSTO} são os alvos ajustados pela subcamada *SSTO*; $\phi(u, y)$ é a mesma função econômica utilizada pelo *RTO*; A_s é a matriz de ganho estático e $d(t|t)$ é a perturbação. Tanto A_s quanto $d(t|t)$ são obtidos a partir do *GPC*, o que novamente garante que os modelos dentro da camada sejam consistentes.

Como resultado da inclusão desta sub-camada, obtém-se um desempenho melhor da estrutura de controle e aumenta-se o retorno econômico. Entretanto, um efeito colateral causado pela utilização de sistemas de otimização de *setpoints* como os apresentados anteriormente, surge em consequência da alteração frequente do ponto de operação. Isto causa um direcionamento também frequente do processo - que geralmente é não linear - a operar em regiões bastante variadas, o que dificulta a obtenção de um modelo linear que mantenha uma boa representatividade nas diferentes regiões, podendo causar problemas como instabilidade e desempenho insuficiente nos controladores baseados nestes modelos.

Este problema é avaliado em (ALVAREZ; ODLOAK, 2010), onde propõe-se solucioná-lo através da integração robusta de uma estrutura de controle que leva em consideração possíveis incertezas na matriz de ganhos estáticos dos modelos. Outra possibilidade é a utilização de técnicas que fazem algum ajuste no modelo durante a execução. Por exemplo, no trabalho apresentado em (KASSMANN et al., 2000), a camada *SSTO* utiliza um modelo fixo complementado por ajustes sucessivos de alguns parâmetros, dentro de um arcabouço de robustez.

Nesta tese propõe-se uma estrutura alternativa de integração de camadas denominada de *RSGi* (*RTO+SSTO+GPC+identificação*), na qual a camada *Supervisório* é aumentada pela inclusão da subcamada *SSTO* e o modelo utilizado dentro dela é continuamente identificado. A solução desenvolvida está apresentada em detalhes no capítulo 3.

3 ESTRATÉGIA DE INTEGRAÇÃO PROPOSTA

RSGi: RTO+SSTO+GPC+identificação

“The technique of process automation has been based on the hierarchical approach for years, with the main layers of the hierarchy being the lower layers of feedback (regulatory) control and the upper layers of optimization... The well-known reason for that is that design of a control unit as a single entity with a homogeneous centralized decision mechanism may be reasonable only in situations in which the process and the control objective are relatively simple.”

(TATJEWSKI, 2008)

Ao final do capítulo anterior apresentaram-se os problemas que surgem como consequência da integração entre o *RTO* e o *GPC*, e algumas alternativas encontradas na literatura para lidar com estes problemas, dentre as quais a inclusão de uma subcamada. Neste capítulo apresenta-se de maneira mais detalhada a estratégia de integração proposta nesta tese, ressaltando o uso de uma subcamada intermediária e da identificação *online* contínua dos modelos.

3.1 APRESENTAÇÃO DA ESTRATÉGIA

Na estratégia de integração proposta, apresentada na figura 3.1, a camada *Supervisorio* é subdividida em duas subcamadas, *SSTO+GPC*. Nestas, utiliza-se um modelo que é continuamente identificado a partir da leitura das variáveis do processo. O modelo é compartilhado, e utilizado em sua versão estacionária na subcamada *SSTO*, e em sua versão dinâmica na subcamada *GPC*. Por fazerem parte da mesma camada, além de compartilharem o modelo, elas compartilham também a frequência de amostragem.

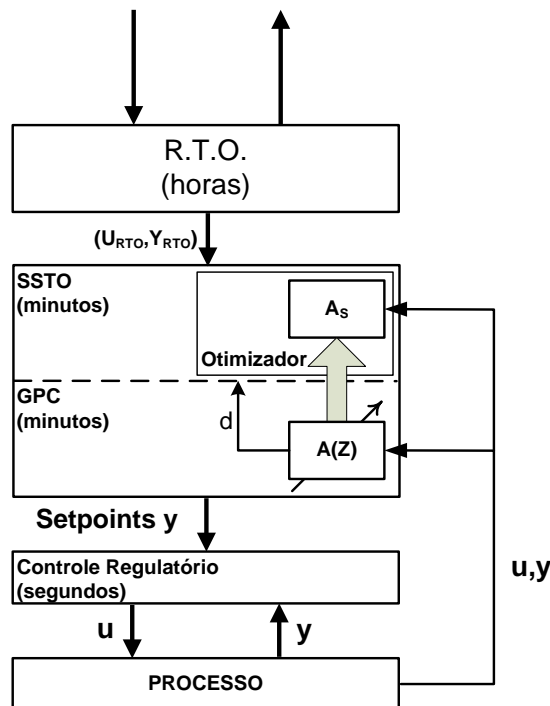


Figura 3.1: Integração RTO-MPC com modelo continuamente identificado

Por sempre estar atualizado, o modelo identificado possui uma boa representatividade do ponto de operação em todos os instantes. Na abordagem comum, baseada em modelos fixos, quando o processo é direcionado pelo *RTO* a um ponto de operação fora do planejado, o controlador preditivo pode apresentar desempenho ruim ou até mesmo levar o sistema à

instabilidade. A inclusão da atualização do modelo diminui a chance de ocorrer instabilidade ou infactibilidade, harmonizando a integração entre as camadas, e melhorando o retorno econômico entre instantes de amostragem de *RTO*.

O controle efetuado na estrutura hierárquica se inicia na camada *RTO* onde resolve-se o problema de otimização apresentado na equação 2.2. Nas camadas seguintes, se encontra a estratégia proposta, na qual a subcamada *SSTO* pode ser implementada na abordagem de proximidade com o ponto de operação (u_{RTO}, y_{RTO}) conforme apresentado na equação 3.1, ou na abordagem de rastreamento econômico baseado no modelo identificado continuamente, conforme apresentado na equação 3.2.

SSTO por proximidade a (u_{RTO}, y_{RTO})	
$\min_{u_{SSTO}, y_{SSTO}} \left\ y_{SSTO} - y_{RTO} \right\ _{Q_s}^2 + \left\ u_{SSTO} - u_{RTO} \right\ _{R_s}^2$ <p>s.a.:</p> $y_{SSTO} = A_s u_{SSTO} + d(t t)$ $y_{SSTO}^{eq} = y^S$ $y^L \leq y_{SSTO}^{in} \leq y^U$ $u^L \leq u_{SSTO} \leq u^U$	(3.1)
SSTO com rastreamento econômico	
$u_{SSTO}, y_{SSTO} = \underset{u, y}{\operatorname{argmin}} \phi_{SSTO}(u, y)$ <p>s.a.:</p> $y_{SSTO} = A_s u_{SSTO} + d(t t)$ $y_{SSTO}^{eq} = y^S$ $y^L \leq y_{SSTO}^{in} \leq y^U$ $u^L \leq u_{SSTO} \leq u^U$	(3.2)

onde y_{SSTO} e u_{SSTO} são os alvos ajustados pela subcamada *SSTO*; $\phi_{SSTO}(u, y)$ é a mesma função econômica utilizada pelo *RTO* com um termo adicional que quantifica a distância ao *setpoint* atual do *RTO*, conforme apresentado na equação 3.3; A_s é a matriz de ganho estático obtida a partir do modelo continuamente identificado e $d(t|t)$ é a perturbação. Tanto A_s quanto $d(t|t)$ são obtidos a partir do *GPC*, o que novamente garante que os modelos dentro da camada sejam consistentes.

A função econômica utilizada na segunda abordagem da subcamada está apresentada na equação 3.3.

$$\phi_{SSTO}(u, y) = \phi(u, y) + \| y_{SSTO} - y_{RTO}^k \|^2_R \quad (3.3)$$

A matriz A_s corresponde à versão estática do modelo dinâmico identificado e utilizado pelo *GPC*. A resposta \hat{y}_{SSTO} obtida com essa matriz está apresentada na equação 3.4.

$$\hat{y}_{SSTO} = A_s u_{SSTO} \quad (3.4)$$

De maneira geral \hat{y}_{SSTO} será diferente da resposta da planta, exceto quando o sistema estiver em um ponto de operação muito próximo ao ponto de linearização do modelo. Portanto, é preciso levar em consideração nos cálculos da camada *SSTO* o erro em relação à resposta da planta. Para tanto, em cada instante é calculada a diferença entre a saída predita pela equação 3.4 e a saída obtida na planta, tomadas no instante imediatamente anterior, conforme apresentado em 3.5.

$$d(k) = y(k-1) - \hat{y}_{SSTO}(k-1) \quad (3.5)$$

onde k é o instante de tempo. Desta forma, compensa-se este erro, e o conjunto de *setpoints* obtidos nesta camada é calculado através da equação 3.6.

$$\begin{aligned} y_{SSTO}(k) &= A_s u_{SSTO}(k) + d(k) \\ y_{SSTO}(k) &= \hat{y}_{SSTO}(k) + d(k) \end{aligned} \quad (3.6)$$

A integração entre as subcamadas é efetuada na função objetivo do problema de minimização do controlador preditivo. O *GPC* implementado utilizando o modelo identificado busca minimizar o critério J_{GPC} , apresentado na equação 3.7, que quantifica a diferença entre o *setpoint* imposto pela subcamada superior e a resposta do modelo às ações futuras de controle. Ao mesmo tempo, as variáveis são mantidas dentro dos limites estabelecidos pelas restrições.

$$J_{GPC} = \sum_{k=1}^{HzPred} (y(k)_{GPC} - y_{SSTO}) + \sum_{k=1}^{HzCtrl} \Delta u(k)_{GPC} \quad (3.7)$$

onde y_{SSTO} é o vetor contendo os *setpoints* determinados pela subcamada *SSTO*, $y(k)_{GPC}$ é o vetor contendo as saídas futuras do modelo em resposta às entradas de controle, $HzPred$ corresponde ao horizonte de previsão do comportamento futuro da saída, e $HzCtrl$ corresponde

ao horizonte de controle das entradas.

3.2 SEQUÊNCIA DE OPERAÇÕES

O diagrama apresentado na figura 3.2 auxilia a entender a sequência de operações realizadas durante a execução da estratégia. Inicialmente, quando surge um novo instante de amostragem da camada *RTO*, esta é acionada, fazendo uma leitura do estado atual do processo, efetuando o cálculo econômico e estabelecendo o ponto de operação de referência (u_{RTO}, y_{RTO}). A seguir, antes do *GPC* entrar em ação, a subcamada *SSTO* faz o ajuste destes *setpoints* que são então repassados ao *GPC*. O controlador preditivo pode então efetuar o seguimento do ponto de operação ajustado (u_{SSTO}, y_{SSTO}) e a rejeição das perturbações de maneira apropriada com o auxílio dos controladores locais. Enquanto o *RTO* não for acionado novamente, a subcamada *SSTO* assume o rastreamento econômico, e em conjunto com as camadas inferiores estabelece uma malha fechada com frequência de amostragem maior.

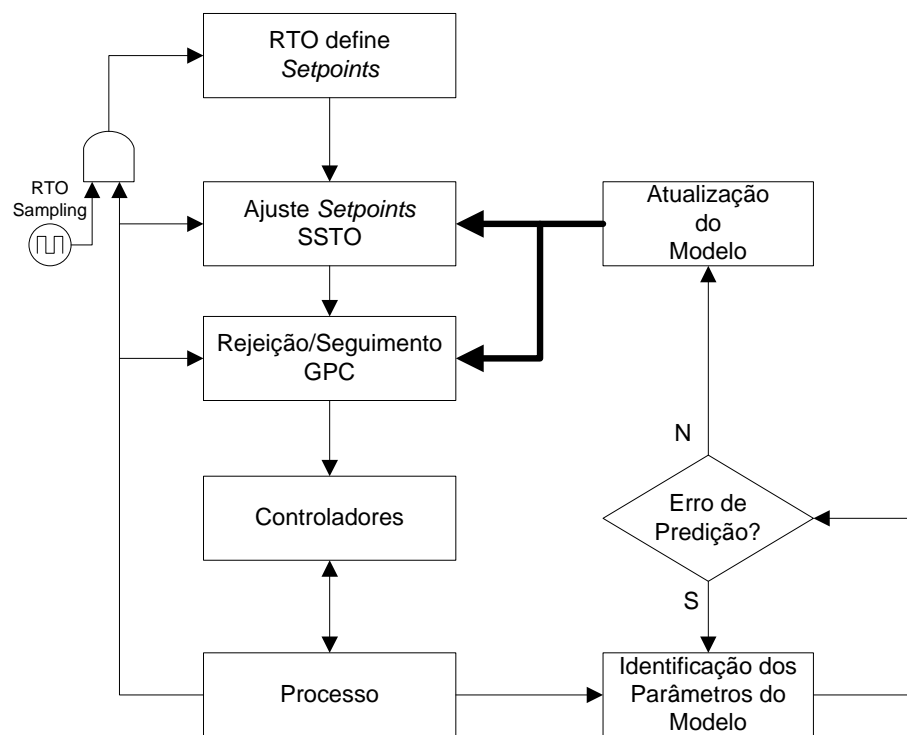


Figura 3.2: Diagrama de implementação da estratégia

Em paralelo à esta sequência de atividades, o módulo de identificação está continuamente monitorando as variáveis do processo e efetuando a identificação de parâmetros do modelo. Calcula-se o erro da predição obtida com o modelo identificado e, caso esta seja menor do que um parâmetro pré-estabelecido, atualizam-se os modelos utilizados nas subcamadas *SSTO* e *GPC*. Utiliza-se neste módulo o Algoritmo de Identificação por

Mínimos Quadrados Recursivo clássico, apresentado originalmente por Gauss (1777-1855), e popularizado posteriormente após estes conceitos terem sido difundidos na área de controle (KALMAN, 1960; LJUNG, 1999).

Nos capítulos seguintes é possível observar o desempenho da estrutura proposta nas simulações em que esta é aplicada em diferentes sistemas.

4 REAÇÃO OTTO

ESTRUTURA APLICADA À REAÇÃO OTTO

“One of the key challenges in the process industry is how to best operate the plant under different conditions such as feed compositions, production rates, energy availability, feed and product prices that changes all the time. Such a task is usually tackled using a supervisory control technique. One such technique that has received considerable attention in the process industry is real-time optimization (RTO)... ”

Adetola e Guay (2010)

Apresentam-se neste capítulo os resultados obtidos com a simulação da estratégia de integração proposta aplicada ao processo Otto. Estes desenvolvimentos iniciais têm por objetivos a familiarização com as técnicas de simulação de processos, com as ferramentas de otimização, com as técnicas de identificação de parâmetros recursiva, o desenvolvimento da implementação das camadas em ambiente matemático *Matlab*[®], e a simulação e comparação das diferentes abordagens aplicadas à subcamada.

Neste primeiro conjunto de simulações da estrutura de controle, implementa-se inicialmente a subcamada *SSTO* em sua abordagem de proximidade aos *setpoints* atuais do *RTO*, e posteriormente em sua abordagem de rastreamento ativo do ponto econômico. As camadas são gradualmente acionadas para destacar-se a contribuição individual de cada uma no desempenho geral do sistema controlado, tanto do ponto de vista de controle quanto do ponto de vista econômico. Conclui-se o capítulo com uma análise dos resultados obtidos.

4.1 MODELO DE REAÇÃO QUÍMICA IMPLEMENTADO

Para iniciar os estudos do desempenho da estrutura de controle proposta, um modelo de processo químico desenvolvido para estudos de controle foi implementado em ambiente computacional. O modelo desenvolvido pela *Monsanto Chemical Company* e apresentado em (WILLIAMS; OTTO, 1960), consiste de um processo que tenta abranger a maioria das situações presentes em uma planta industrial: Reações químicas, troca de calor, refluxo, destilação multi-estágios. As equações diferenciais para este processo, que se encontram no apêndice A, foram discretizadas e simuladas através de um método de passo simples.

A planta considerada tem o objetivo de produzir 40.000.000 *lb/ano* de um produto *P*, cuja natureza não é especificada. A natureza das substâncias não é especificada, mas isso é aceitável para fins de estudos de controle. As equações das reações químicas que acontecem no início deste processo químico estão mostradas na figura 4.1.




Figura 4.1: Equações das reações químicas

Os reagentes iniciais A e B estão disponíveis a partir de unidades de processamento anteriores da planta industrial. As substâncias C e E são produtos intermediários da reação, e não possuem valor comercial, apesar de poderem ser utilizados como combustível. Já a substância G é um óleo pesado que deve ser descartado.

As velocidades das equações I , II e III são definidas pela equação de *Arrhenius*, onde T_i é a temperatura da reação (em $^{\circ}C$):

Tabela 4.1: Velocidade das três reações envolvidas

$k_i = A_i \cdot e^{-B_i/T_i}$		
Reação	Coefficiente A_i (h^{-1})	Coefficiente B_i ($^{\circ}Ra$)
I	$5,9755 \cdot 10^9$	12000
II	$2,5962 \cdot 10^{12}$	15000
III	$9,6283 \cdot 10^{15}$	20000

As três reações são exotérmicas, e a composição dos produtos obtida é dependente da temperatura, o que implica na necessidade de controlar a temperatura do reator e, posteriormente, na necessidade de resfriar a vazão de saída do reator. Esta é direcionada posteriormente a um separador para retirada da substância G por decantação. Segue então para uma coluna de destilação para separar parte da substância leve P . Uma parte da fração pesada é direcionada para o refluxo e a outra parte é aproveitada.

Na figura 4.2 apresentam-se as partes que compõem o processo onde notam-se as vazões mássicas de alimentação F_A e F_B , que são consideradas como fornecidas por uma etapa anterior e sempre disponíveis, a vazão mássica na saída do trocador de calor F_R (composta por

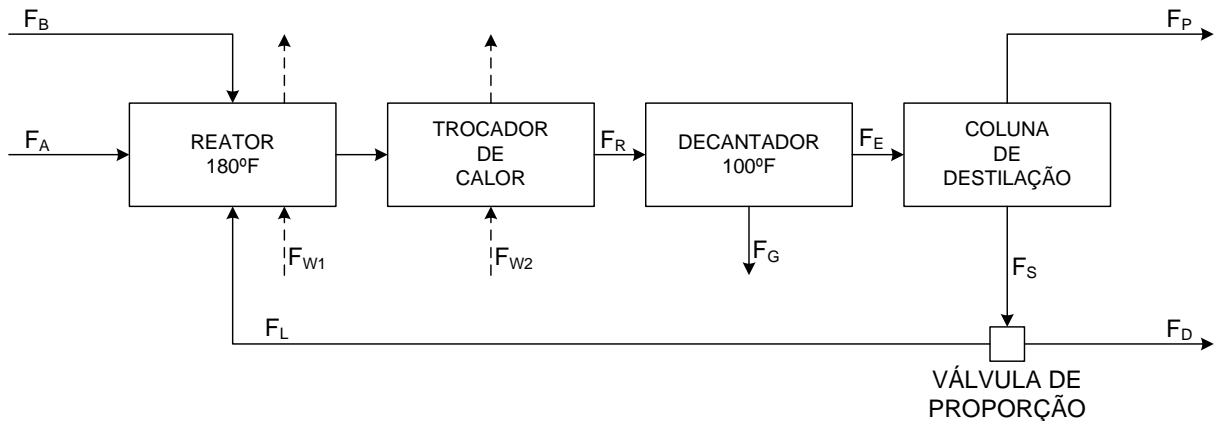


Figura 4.2: Partes que compõem o processo

frações das substâncias A, B, C, P, E, G), a vazão mássica do produto descartado F_G , a vazão mássica após o decantador F_E , as vazões mássicas da fração pesada F_S e da fração leve F_P após a coluna de destilação, e por fim a válvula de proporção que direciona parte da fração leve para constituir a vazão mássica de refluxo F_L , e a outra parte para ser aproveitada em F_D . É possível notar também a vazão dos fluidos de aquecimento no reator F_{W1} e de resfriamento no trocador de calor F_{W2} .

Para o estudo proposto neste trabalho, uma versão simplificada do processo foi implementada, em que considerou-se uma coluna que destila sempre a mesma proporção de substância P , e um separador que retira sempre a mesma proporção da substância G decantada, ambos com dinâmica desprezível. As reações e o refluxo, por outro lado, são dinâmicos. A introdução de um modelo dinâmico da coluna e do separador implicaria em uma complexidade maior na simulação do processo, sem que necessariamente trouxesse vantagens para a análise do sistema de controle proposto. Desta forma é possível estudar sistemas de controle com foco no rastreamento do ótimo econômico, que está diretamente ligada às proporções dos compostos produzidos, ignorando possíveis atrasos introduzidos pelas dinâmicas desprezadas.

Na figura 4.3 apresenta-se a tabela retirada do artigo original contendo os valores de estado estacionário esperados para as vazões e concentrações.

Maiores informações sobre o modelo podem ser encontradas no apêndice A e também no artigo (WILLIAMS; OTTO, 1960). Com o modelo dinâmico implementado é possível partir para os estudos de controle.

Compo- nent	Stream																	
	F _A		F _B		F _R		F _E		F _G		F _P		F _S		F _L		F _D	
	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction	Rate, Lb/Hr	Weight Fraction
A...	14,500	1.000			11,628	0.121	11,628	0.126					11,628	0.133	6,393	0.133	5,235	0.133
B.....			33,350	1.000	36,829	0.383	36,829	0.399					36,829	0.421	20,255	0.421	16,574	0.421
C.....					2,348	0.025	2,348	0.026					2,348	0.027	1,289	0.027	1,059	0.027
E.....					33,348	0.346	33,348	0.361					33,348	0.381	18,340	0.381	15,007	0.381
P.....					8,096	0.085	8,096	0.088			4,763	1.000	3,334	0.038	1,834	0.038	1,501	0.038
G.....					3,712	0.039			3,712	1.000								
Total	14,500	1.000	33,350	1.000	95,961	1.000	92,249	1.000	3,712	1.000	4,763	1.000	87,487	1.000	48,111	1.000	39,376	1.000

Figura 4.3: Tabela com os valores das vazões e concentrações
 Fonte: retirado de Williams e Otto (1960).

4.2 ESTRATÉGIA RSGi APLICADA À REAÇÃO DE OTTO

Aplicou-se a estratégia de integração de camadas RSGi ao processo Otto para avaliar o desempenho da estrutura de controle no rastreamento do ótimo econômico. Em um primeiro momento simulou-se o modelo da reação de Otto para fins de validação do mesmo. Na comparação dos valores relativos a F_R (Vazão mássica na saída dos componentes na saída do reator), apresentados na terceira coluna da tabela da figura 4.3, com os valores obtidos na simulação do modelo, que estão apresentados na figura 4.4, obteve-se resultados muito próximos indicando que o modelo está consistente.

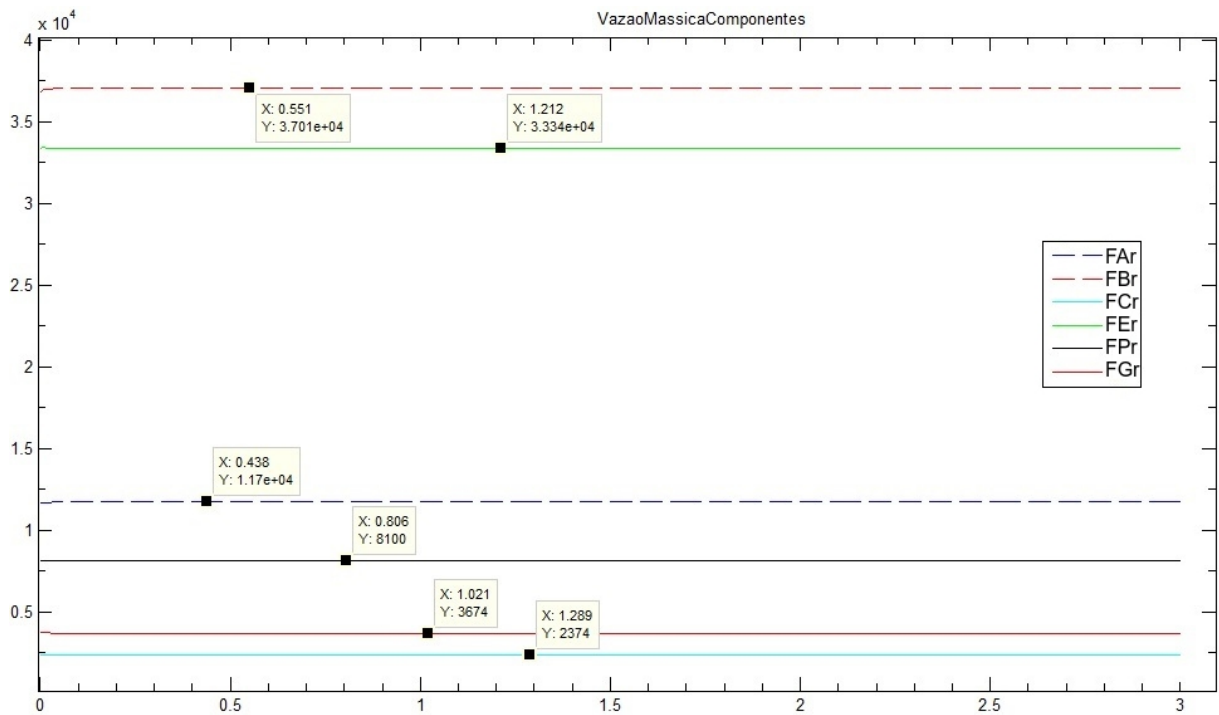


Figura 4.4: Validação do modelo - Vazões mássicas na saída do reator [lb/h]

Implementou-se inicialmente a camada de controle regulatório através de dois

controladores *PI*. A primeira malha de controle está estabelecida no controle da temperatura do reator através da atuação na temperatura do fluido de aquecimento F_{W1} . A segunda malha de controle está estabelecida na vazão do refluxo, através da atuação direta na válvula de proporção.




Figura 4.5: Malhas de controle

Acima da camada de controle regulatório encontra-se a camada *Supervisório* que é constituída pelo controlador preditivo responsável por estabelecer os *setpoints* enviados aos controladores *PI*'s locais. Implementou-se a abordagem *GPC* baseada em modelos *FOPDT* (*First Order Plus Dead Time*), ou seja modelos de primeira ordem mais atraso entre entrada e saída. Apesar de sua simplicidade, estes modelos são muito utilizados na indústria para descrever a dinâmica de muitos processos diferentes (BORDONS; CAMACHO, 1998; BAGHERI; SEDIGH, 2013). Estes modelos podem ser descritos como apresentado na equação 4.1, para o caso discreto, onde a_1 e b_0 são os coeficientes do modelo discreto, z é o operador deslocamento e d é o atraso.

$$G(z) = \frac{Y(z)}{U(z)} = \frac{b_0 \cdot z^{-d}}{1 + a_1 z^{-1}} \quad (4.1)$$

O modelo a partir do qual baseiam-se as previsões do *GPC*, é um modelo 2×6 que relaciona as variáveis Temperatura do Reator e Vazão de Refluxo (T_R, F_L) com as frações de cada substância ($F_{A_R}, F_{B_R}, F_{C_R}, F_{E_R}, F_{G_R}, F_{P_R}$) na vazão mássica de saída do reator F_R . Sua estrutura está apresentada na figura 4.6. Nota-se nesta mesma figura que as relações entre as vazões de alimentação do reator (F_A, F_B) com as vazões de saída não estão presentes no modelo, e portanto pode-se considerá-las como variáveis de perturbação para o modelo.




Figura 4.6: Estrutura do modelo utilizado no GPC

O modelo médio foi identificado *offline* na região em torno do ponto de operação dado por $(T_{R_0}, F_{L_0}) = (180, 48111)$. Um sinal pseudo-aleatório foi aplicado em T_R , e observou-se a resposta do sistema, enquanto F_L foi mantido constante em 48111 lb/h. A seguir, aplicou-se um sinal pseudo-aleatório em F_L e observou-se a resposta do sistema, enquanto manteve-se T_R constante em uma temperatura de 180 °F. Em posse destes dados, as relações entre entradas e saídas foram identificadas utilizando o *System Identification Toolbox* pertencente ao ambiente matemático Matlab[®] e estão apresentadas na tabela 4.2 juntamente com os pontos de operação.

Tabela 4.2: Modelos identificados para uso no GPC

$F_{A_0} = 11673$	$\Delta F_A(s) = -\frac{51.1600 z^{-1}}{1-0.6978 z^{-1}} \Delta T_R(s) + \frac{0.1523 z^{-1}}{1+0.1891 z^{-1}} \Delta F_L(s)$
$F_{B_0} = 36912$	$\Delta F_B(s) = -\frac{120.2000 z^{-1}}{1-0.5681 z^{-1}} \Delta T_R(s) + \frac{0.4731 z^{-1}}{1+0.1769 z^{-1}} \Delta F_L(s)$
$F_{C_0} = 2368$	$\Delta F_C(s) = -\frac{20.9900 z^{-1}}{1-0.6089 z^{-1}} \Delta T_R(s) + \frac{0.0331 z^{-1}}{1+0.1469 z^{-1}} \Delta F_L(s)$
$F_{E_0} = 33240$	$\Delta F_E(s) = +\frac{75.3300 z^{-1}}{1-0.7172 z^{-1}} \Delta T_R(s) + \frac{0.2273}{1-0.4483 z^{-1}} \Delta F_L(s)$
$F_{P_0} = 8090$	$\Delta F_P(s) = +\frac{43.0700 z^{-1}}{1+0.4459 z^{-1}} \Delta T_R(s) + \frac{0.0486}{1+0.0990 z^{-1}} \Delta F_L(s)$
$F_{G_0} = 3678$	$\Delta F_G(s) = +\frac{34.6100 z^{-1}}{1-0.6958 z^{-1}} \Delta T_R(s) - \frac{0.0176}{1+0.1959 z^{-1}} \Delta F_L(s)$

Os modelos apresentaram, nos testes de validação, de acordo com as recomendações de (LJUNG, 1999), uma boa representatividade como pode ser visto na figura 4.7 onde o sistema

original e o modelo identificado foram submetidos às mesmas entradas. A resposta do sistema original está traçada em linha contínua e a resposta do modelo identificado em linha tracejada.

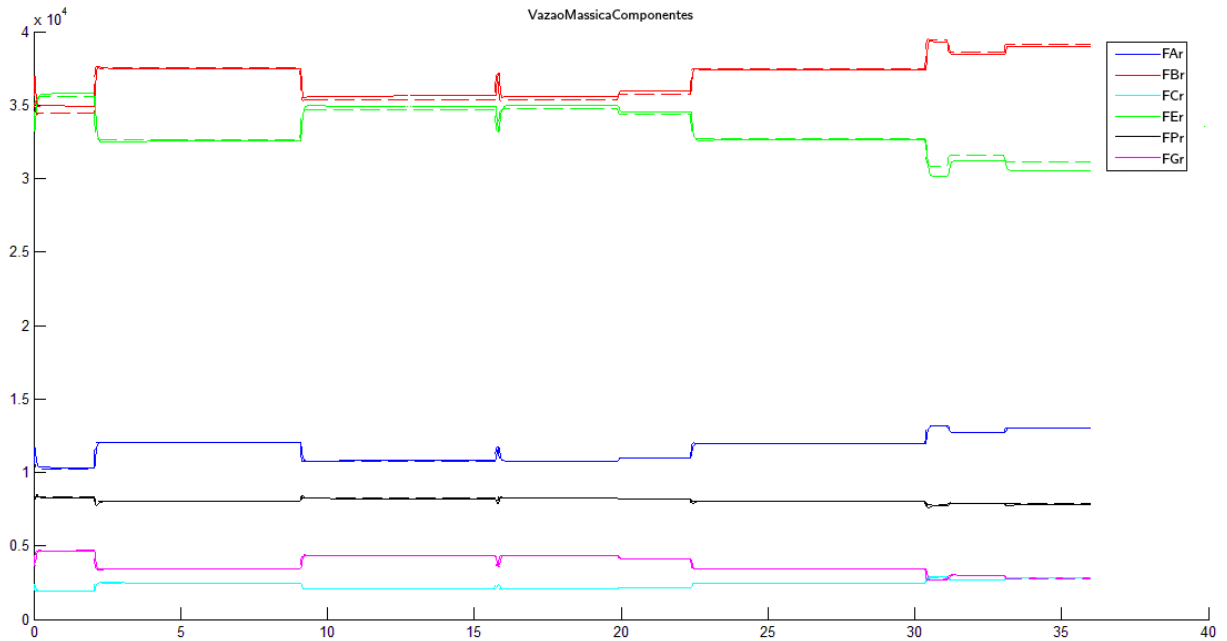


Figura 4.7: Vazão mássica na saída do reator sistema original x modelo identificado [lb/h]

Resta ainda, de acordo com a estratégia apresentada no capítulo 3, a inclusão das subcamadas e da camada de otimização, que corresponde à camada onde implementa-se o otimizador em tempo real. Utilizou-se no *RTO* a versão estacionária do modelo da reação de Otto apresentado no apêndice A, que é o mesmo modelo utilizado na simulação do processo, e que portanto, elimina a necessidade da etapa de reconciliação de dados. A formulação do problema de otimização está apresentada na equação 4.2.

$$u_{RTO} = \underset{u}{\operatorname{argmin}} -\$R(u, y)$$

s.a.

$$y = \text{Otto}_{est}(u, \theta) \quad (4.2)$$

$$y^{eq} = y^S$$

$$y^L \leq y^{in} \leq y^U$$

$$u^L \leq u \leq u^U.$$

onde $\$R$ representa o retorno econômico do processo avaliado no ponto de operação determinado por (u, y) ; u representa as entradas do processo, y as saídas e θ os parâmetros do modelo; Otto_{est} é a versão estacionária das equações de balanço de massa e de energia

da reação Otto contidas no apêndice A; y^{eq} é o conjunto de saídas para as quais impõe-se igualdade a algum valor y^S ; y^{in} é o conjunto de saídas para as quais impõe-se limites inferiores y^L e superiores y^U ; u^L e u^S são respectivamente os limites inferior e superior para as entradas.

O *RTO* implementado consiste de um otimizador que busca, quando acionado, o ponto de operação da planta com o melhor resultado econômico. Para calcular o resultado econômico associado ao ponto de operação corrente, utiliza-se a porcentagem de retorno econômico $\%R$, desenvolvida em (WILLIAMS; OTTO, 1960), e apresentada na equação 4.3

$$\%R(u, y) = 100 \cdot \left(\frac{8.400M - 2,22F_R - 0,124 \left(\frac{8.400}{0,3F_P + 0,0068F_D} \right) - 276.000}{2.780.000} \right) \quad (4.3)$$

onde os termos relacionados aos custos são: $2,22F_R$ que representa o custo associado à utilização da planta (que pode ser estimado através de uma relação com a vazão na saída do reator); $0,124(8400/(0,3F_P + 0,0068F_D))$ que representa os custos administrativos e de desenvolvimento da planta; 276.000 que representa os custos fixos; $2.780.000$ que representa o investimento total na planta; e onde M é o termo associado ao retorno obtido com a utilização da planta, pois representa o retorno bruto por hora cujo cálculo está apresentado na equação 4.4.

$$M = 0,3F_P + 0,0068F_D - 0,02F_A - 0,03F_B - 0,01F_G \quad (4.4)$$

onde os custos estão associados ao consumo de A e B , que são a alimentação do reator, e ao produto G que deve ser descartado e não é comercializável; e os ganhos estão associados à comercialização de P , que é o principal produto a ser comercializado, e à utilização dos produtos obtidos na fração pesada da coluna que não são direcionados para o refluxo.

Ao final dos cálculos de otimização, os *setpoints* determinados pela camada *RTO* são intermediados pela subcamada *SSTO*. No conjunto de simulações apresentados neste capítulo, implementou-se inicialmente a abordagem de distância mínima quadrática aos *setpoints* determinados pelo *RTO*, conforme apresentado na equação 4.5. Em um segundo momento, implementou-se a abordagem do rastreamento econômico ativo na subcamada, conforme apresentado na equação 4.6.

$$\min_{u_{SSTO}, y_{SSTO}} \|y_{SSTO} - y_{RTO}\|_{Q_s}^2 + \|u_{SSTO} - u_{RTO}\|_{R_s}^2$$

s.a.:

$$y_{SSTO} = A_s u_{SSTO} + d(t|t)$$

$$y_{SSTO}^{eq} = y^S$$

$$y^L \leq y_{SSTO}^{in} \leq y^U$$

$$u^L \leq u_{SSTO} \leq u^U$$

(4.5)

$$u_{SSTO} = \underset{u}{\operatorname{argmin}} -\$R_{SSTO}(u, y)$$

s.a.:

$$y_{SSTO} = A_s u_{SSTO} + d(t|t)$$

$$y_{SSTO}^{eq} = y^S$$

$$y^L \leq y_{SSTO}^{in} \leq y^U$$

$$u^L \leq u_{SSTO} \leq u^U$$

(4.6)

onde $\$R_{SSTO}$ é o retorno econômico da reação de Otto apresentado na equação 4.7; y_{RTO} e u_{RTO} são os *setpoints* determinados na camada *RTO* para as saídas e entradas respectivamente; y_{SSTO} e u_{SSTO} são os alvos ajustados pela subcamada *SSTO*, e correspondem respectivamente aos *setpoints* para as saídas (F_A, F_B, \dots, F_G) e para as entradas (F_R, T_L); A_s é a matriz de ganhos estáticos e $d(t|t)$ é a perturbação. A matriz A_s utilizada em 4.5, e apresentada na equação 4.8 (que será explicada em maiores detalhes a seguir), corresponde à versão estática do modelo dinâmico utilizado pelo *GPC* apresentado na tabela 4.2.

A equação do retorno econômico utilizado na subcamada é ligeiramente diferente daquela utilizada pelo *RTO*, pois possui adicionalmente um termo para quantificar a distância do ponto (u_{SSTO}, y_{SSTO}) aos *setpoints* atuais do *RTO*, como apresentado na equação 4.7.

$$\$R(u, y)_{SSTO} = \$R(u, y) + \lambda \|y_{SSTO} - y_{RTO}^k\|_R^2 \quad (4.7)$$

onde $\$R(u, y)$ é a equação do retorno econômico usada no *RTO*, λ é um peso de ponderação, k representa a iteração do *RTO*, e $\|y_{SSTO} - y_{RTO}^k\|_R^2$ quantifica a distância do ponto de operação escolhido em relação ao *setpoint* vigente.

$$\begin{bmatrix} \hat{F}_{ASSTO} \\ \hat{F}_{BSSTO} \\ \hat{F}_{CSSTO} \\ \hat{F}_{ESSTO} \\ \hat{F}_{PSSTO} \\ \hat{F}_{GSSTO} \end{bmatrix} = \overbrace{\begin{bmatrix} \frac{-51.1600}{1-0.6978} & \frac{+0.1523}{1+0.1891} \\ \frac{-120.2000}{1-0.5681} & \frac{+0.4731}{1+0.1769} \\ \frac{-20.9900}{1-0.6089} & \frac{+0.0331}{1+0.1469} \\ \frac{+75.3300}{1-0.7172} & \frac{+0.2273}{1-0.4483} \\ \frac{+43.0700}{1+0.4459} & \frac{+0.0486}{1+0.0990} \\ \frac{+34.6100}{1-0.6958} & \frac{-0.0176}{1+0.1959} \end{bmatrix}}^{A_s} \cdot \begin{bmatrix} T_{RSSTO} \\ F_{LSSTO} \end{bmatrix} \quad (4.8)$$

Nas simulações deste capítulo o *GPC* mantém a mesma função de custo, que está apresentada na equação 4.9.

$$J_{GPC} = \sum_{k=1}^{HzPred} (y(k)_{GPC} - y_{SSTO}) + \sum_{k=1}^{HzCtrl} \Delta u(k)_{GPC} \quad (4.9)$$

Na seção seguinte, apresenta-se o resultado de simulações que ilustram o desempenho da estrutura de controle completa no rastreamento do ponto ótimo econômico.

Os ajustes dos parâmetros do controlador preditivo estão apresentados no apêndice B.

4.3 RESULTADOS OBTIDOS COM A ESTRUTURA DE CONTROLE

Apresentam-se a seguir quatro simulações idealizadas para expor o desempenho da estratégia de integração proposta no controle do processo atrelado ao rastreamento do ótimo econômico, nas quais submete-se o processo *Otto* a uma perturbação na vazão de alimentação F_A . Na primeira simulação o processo é controlado unicamente pelo *GPC* e observa-se o comportamento do sistema em resposta a esta perturbação. Na segunda aciona-se adicionalmente a camada *RTO* para mostrar sua capacidade de rastreamento econômico, e na terceira aciona-se adicionalmente a subcamada *SSTO* em sua abordagem de proximidade a (u_{RTO}, y_{RTO}) , para ressaltar o aumento do retorno econômico entre os instantes de amostragem do *RTO*. A seguir, na quarta simulação, aciona-se a estrutura completa, porém implementada na abordagem de rastreamento econômico ativo na subcamada *SSTO*, o que causa um impacto positivo no rendimento econômico. Pretende-se desta forma mostrar a influência individual de

cada camada no resultado econômico, evidenciar que a ausência desta estrutura pode implicar em perdas econômicas, e também comparar as abordagens distintas para a subcamada.

4.3.1 PRIMEIRA SIMULAÇÃO

Submete-se então o sistema a uma perturbação que aumenta em 20% a vazão de alimentação F_A no instante $k = 50$, e mantêm-se desativadas a camada *RTO* e a subcamada *SSTO*. A vazão mássica na saída do reator, direcionada pelo *GPC*, está apresentada na figura 4.8 em linha tracejada, juntamente com os respectivos *setpoints* em linha contínua. Nota-se que o *GPC* responde à perturbação em F_A forçando a saída do sistema a estar o mais próximo possível das referências previamente determinadas.

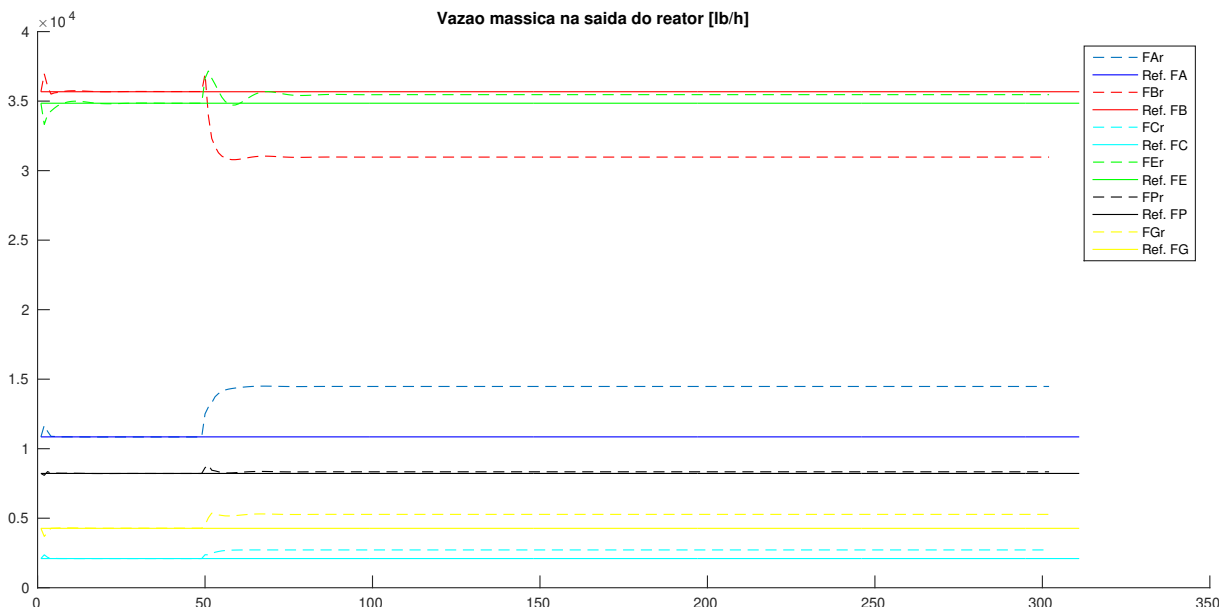


Figura 4.8: Resposta do sistema à uma perturbação quando apenas o *GPC* está acionado

Se do ponto de vista de controle o comportamento do *GPC* é adequado pois, em resposta a uma perturbação, ele força as saídas do sistema de volta aos *setpoints*, do ponto de vista econômico a atuação do controlador não faz tanto sentido. Isto pode ser observado na figura 4.9, onde apresenta-se a evolução do retorno econômico para a mesma simulação. Nesta figura, fica claro que a partir do instante em que a perturbação ocorre ($k = 50$), a atuação do *GPC* piorou o retorno econômico do sistema, diminuindo-o de um valor em torno de 120% para um valor em torno de 97%, ainda que o sistema esteja bem controlado. Esta situação ilustra bem como um sistema de controle que não leva em consideração aspectos econômicos, pode causar uma perda financeira em resposta a possíveis perturbações.

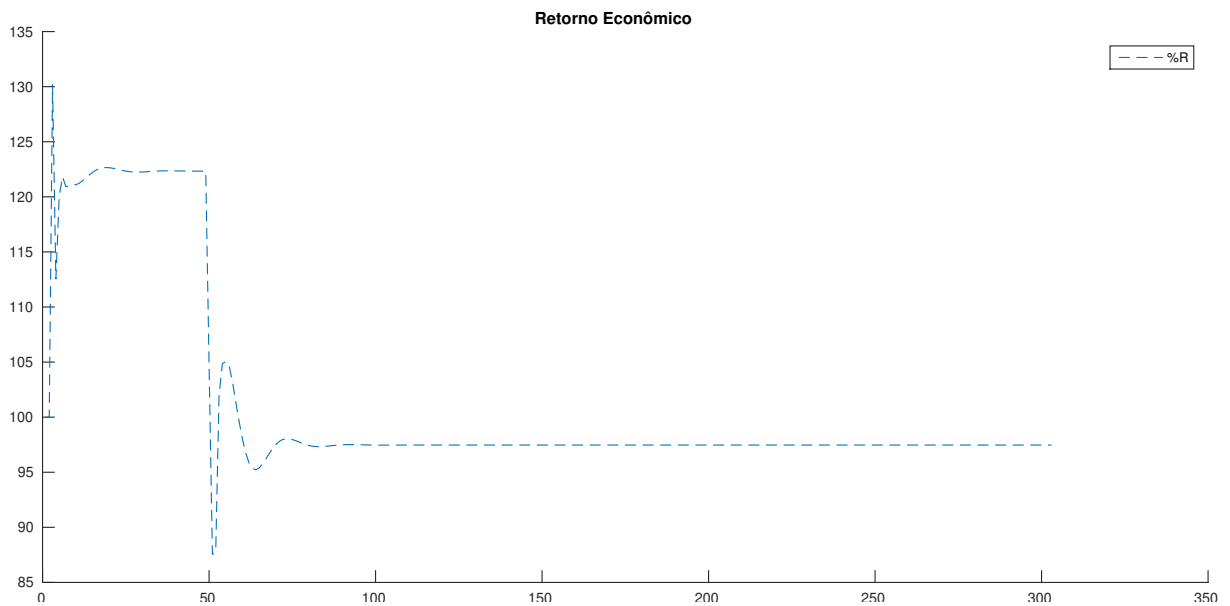


Figura 4.9: Resultado econômico do sistema quando apenas o *GPC* está acionado

4.3.2 SEGUNDA SIMULAÇÃO

Na segunda simulação, o sistema é submetido à mesma perturbação na vazão de alimentação F_A , no instante $k = 50$. Neste caso, entretanto, aciona-se a camada *RTO* no instante $k = 150$, que reconhece a perturbação na vazão e calcula o novo ponto de operação ótimo correspondente. A figura 4.10 mostra as novas referências, que correspondem ao novo ponto de operação, impostas pelo *RTO* a partir do instante $k = 150$. Na mesma figura, a partir do instante $k = 150$ em diante, é possível observar o *GPC* direcionando o sistema para este novo ponto de operação.

Para verificar se este novo ponto de operação de fato se traduz em uma melhora no retorno econômico, é preciso comparar o retorno econômico antes e depois do instante $k = 150$. Apresenta-se a evolução do retorno econômico na figura 4.11, na qual nota-se que o acionamento da camada *RTO* causa uma melhora do retorno econômico, pois após o seguimento das novas referências, o retorno econômico é aumentado de um valor em torno de 97% para um valor em torno de 117%.

Por outro lado, desde o instante da perturbação até o instante em que o *RTO* é acionado, ou seja, entre $k = 50$ e $k = 150$, o sistema apresenta um resultado econômico inferior. Para estes intervalos de tempo, desde o instante em que ocorre uma perturbação até o instante em que o *RTO* é acionado, existe espaço para melhorar o resultado econômico. Um dos objetivos de se utilizar a subcamada *SSTO* é justamente este, o de melhorar o rastreamento do ótimo econômico entre os instantes de amostragem do *RTO*.

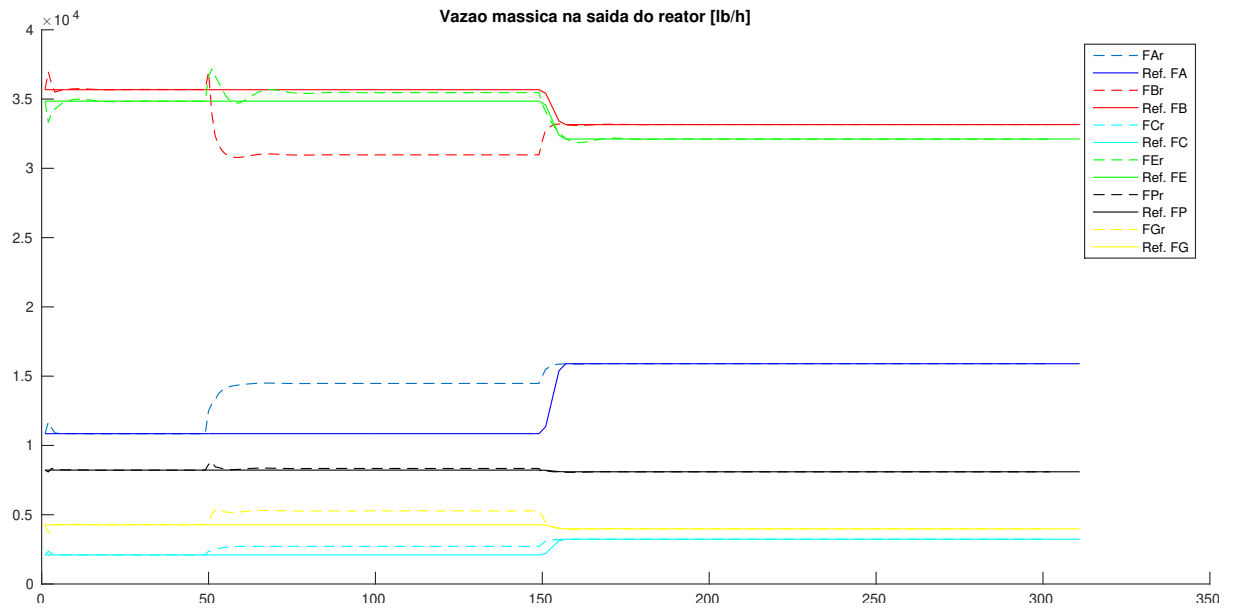


Figura 4.10: Resposta do sistema a uma perturbação quando *RTO-GPC* estão acionadas




Figura 4.11: Resultado econômico do sistema quando *RTO-GPC* estão acionadas

4.3.3 TERCEIRA SIMULAÇÃO

Na terceira simulação, a subcamada é acionada entre os instantes $k = 100$ e $k = 150$, em sua abordagem de proximidade com os *setpoints* (u_{RTO}, y_{RTO}) . A subcamada foi propositalmente acionada neste intervalo, para que os efeitos decorrentes de sua utilização possam ser comparados com a simulação anterior, na qual ela não foi acionada. Quando a camada *SSTO* é acionada, os *setpoints* são reajustados e o *GPC* direciona o sistema para este novo ponto de operação. A figura 4.12 apresenta o comportamento do sistema nesta simulação.

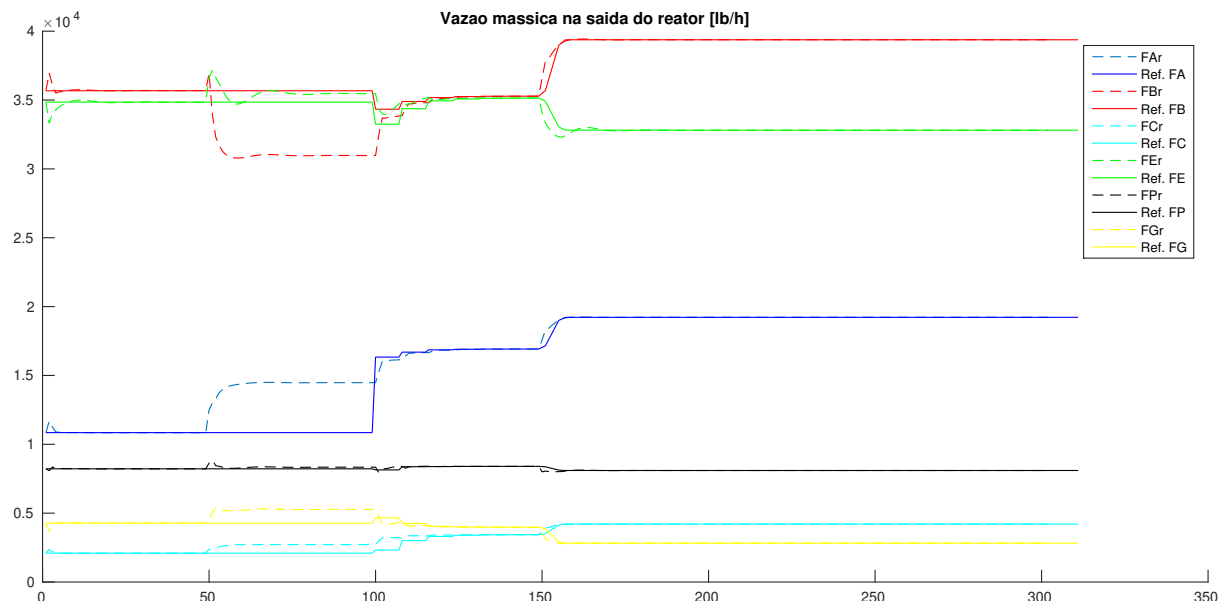


Figura 4.12: Resposta do sistema à uma perturbação quando *RTO-SSTO-GPC* estão acionadas

Durante todo este intervalo, o reajuste dos *setpoints* feito pela subcamada não causou impactos negativos do ponto de vista de controle, pois o sistema se manteve controlado, sem incorrer em instabilidades. E ainda, do ponto de vista econômico, é interessante notar na figura 4.13, como o acionamento da camada *SSTO* diminui a perda econômica causada pela perturbação para esta simulação em particular, melhorando o retorno econômico de 97% para um valor em torno de 103%. Ainda que este ponto de operação seja sub-ótimo, pois um resultado econômico ainda melhor será atingido quando a camada *RTO* for acionada novamente em $k = 150$, é inegável que a camada *SSTO* trouxe benefícios para este caso específico, direcionando o sistema no sentido do ótimo econômico antes da nova iteração de *RTO*.

A terceira simulação foi repetida, novamente com toda a estrutura *RTO+SSTO+GPC* em uso, porém desta vez com uma perturbação que diminui em 20%, ao invés de aumentar, a vazão de alimentação F_A , no instante $t = 50$. As figuras, 4.13 e 4.14, que apresentam o resultado econômico para as duas perturbações diferentes, estão apresentadas em conjunto, na página 65,

para melhor visualização.

A análise do resultado econômico para este novo ensaio mostra que desta vez não é interessante utilizar a camada *SSTO*. Para este caso em particular, a própria atuação do *GPC* na rejeição à perturbação, traz o sistema para um ponto de operação com um resultado econômico melhor, pois quando a subcamada é acionada, o retorno econômico cai de um valor em torno de 127% para um valor em torno de 122%. O motivo para isto ocorrer está ligado à abordagem utilizada para a subcamada.

Como já estabelecido anteriormente, na equação 3.1, a abordagem utilizada para a subcamada neste conjunto de simulações é a de proximidade com os *setpoints* $\|y_{SSTO} - y_{RTO}\|_{Q_s}^2$ e $\|u_{SSTO} - u_{RTO}\|_{R_s}^2$. O fato de estar a uma distância mínima quadrática dos pontos determinados pelo *RTO* não é garantia de estar num ponto econômico melhor, ainda que como resultado final seja atingido um ponto de operação factível. Desta forma, esta abordagem atinge o objetivo de minimizar as possíveis inconsistências de modelos diferentes nas camadas, e também de suavizar as transições entre pontos de operação diferentes pois é eficiente para encontrar soluções factíveis para o *GPC*, bem como ela é capaz de antecipar a reação às perturbações econômicas quando comparada aos instantes de amostragem do *RTO*, mas efetivamente ela não consegue garantir melhoria do resultado econômico.

A comparação das figuras indica que é necessário a modificação da abordagem da subcamada tendo em vista melhorar o rendimento econômico obtido em qualquer situação, independente do valor da perturbação econômica que possa vir a ocorrer.

4.3.4 QUARTA SIMULAÇÃO

Na quarta simulação, repetem-se os passos seguidos na simulação anterior, mas utiliza-se agora, a abordagem de rastreamento econômico ativo na subcamada.

Com a estrutura *RSGi* implementada, submeteu-se o processo aos mesmos procedimentos, ou seja, no instante $t = 50$, a vazão de alimentação F_A sofre um aumento de 20%. A subcamada foi acionada no instante $t = 100$ e o *RTO* no instante $t = 150$. Nesta simulação, utilizou-se a estrutura *RTO-SSTO-GPC* com a subcamada em sua abordagem de rastreamento econômico ativo, de maneira similar à descrição apresentada na equação 3.2. O resultado econômico obtido neste ensaio está apresentado na figura 4.15.

A seguir, o mesmo procedimento foi seguido, mas submete-se a vazão de alimentação F_A a uma diminuição de 20%. Nesta vez, independentemente do valor da perturbação em F_A , a estrutura implementada conseguiu melhorar o rendimento econômico, o que pode ser notado

na figura 4.16.

As figuras 4.15 e 4.16, contendo o resultado econômico para as simulações com os dois valores diferentes de F_A estão apresentadas em conjunto na página 66, para melhor visualização. Como pode-se notar em ambas, o acionamento da subcamada entre $t = 100$ e $t = 150$, causou um aumento no retorno econômico, antes que o *RTO* fosse novamente acionado.

Desta forma, esta estrutura se mostra capaz de atingir os objetivos inicialmente propostos de harmonizar a integração das camadas, e aumentar a frequência do rastreamento econômico, mantendo o sistema controlado e estável.

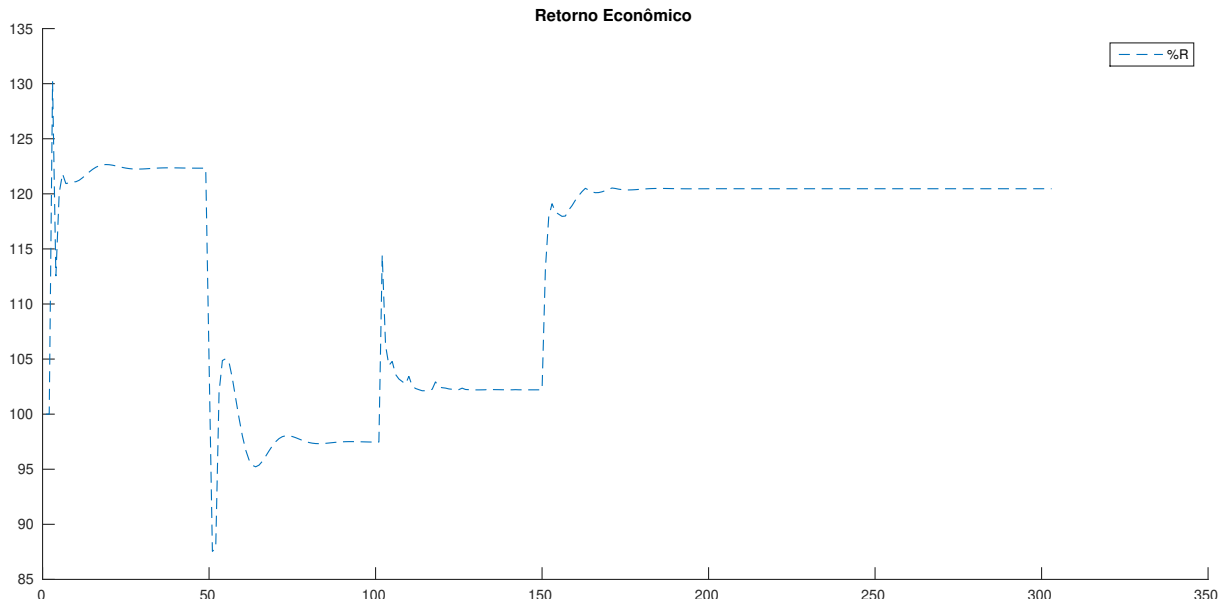


Figura 4.13: Resultado econômico quando $F_A = +20\%$ e *RTO-SSTO-GPC* implementada com proximidade a (u_{RTO}, y_{RTO})




Figura 4.14: Resultado econômico quando $F_A = -20\%$ e *RTO-SSTO-GPC* implementada com proximidade a (u_{RTO}, y_{RTO})

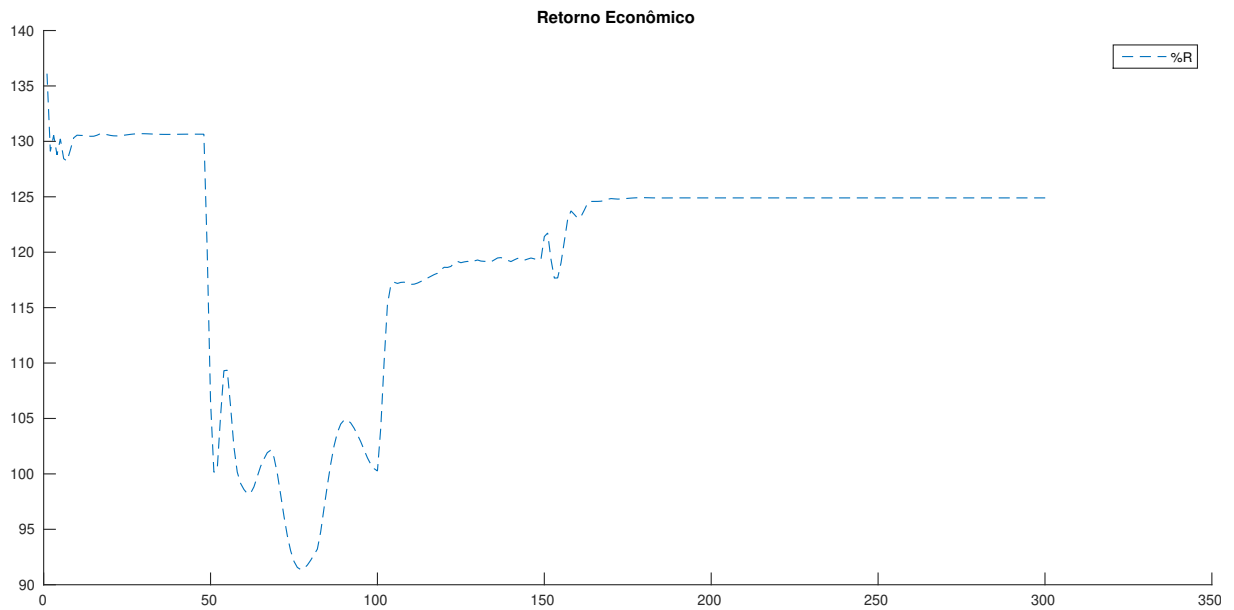


Figura 4.15: Resultado econômico quando $F_A = +20\%$ e *RTO-SSTO-GPC* implementada com rastreamento econômico




Figura 4.16: Resultado econômico quando $F_A = -20\%$ e *RTO-SSTO-GPC* implementada com rastreamento econômico

4.4 DISCUSSÕES

A utilização da estratégia no processo de *Otto* apresentou um desempenho bom, do ponto de vista do problema de controle. A subcamada incluída foi capaz de gerar *setpoints* alcançáveis pelo controlador preditivo sem que houvesse ocorrência de *offsets*, não ocorrendo nenhum caso de infactibilidade. O ajuste de *setpoints* efetuado na mesma suavizou a transição

entre pontos de operação diferentes após um novo instante de amostragem da camada *RTO*. Fica claro também que apesar de conseguir entregar estas vantagens, a abordagem de proximidade ao ponto de operação (u_{RTO}, y_{RTO}) não garante melhoria do retorno econômico, pois em algumas vezes ela se mostra menos vantajosa do que deixar o sistema controlado apenas pelo controlador *GPC*, o que certamente é um ponto fraco importante desta abordagem.

Por outro lado, os resultados obtidos com a implementação da estratégia proposta, na qual utiliza-se a abordagem de rastreamento econômico na subcamada, se mostraram bastante promissores em termos de melhorar o retorno econômico no caso de ocorrência de perturbações econômicas mais rápidas, mantendo as vantagens obtidas na implementação anterior.

O ganho econômico da segunda abordagem em relação à primeira é expressivo. Na ocorrência da perturbação de +20% em F_A , a segunda abordagem consegue atingir um retorno econômico de aproximadamente 120% frente a aproximadamente 103% obtido com a primeira abordagem. Já na ocorrência da perturbação de -20% em F_A , a segunda abordagem consegue atingir um retorno econômico de aproximadamente 145% frente a um retorno econômico de aproximadamente 122% na primeira abordagem, o que quer dizer que a estrutura de controle conseguiu levar o sistema a um rendimento econômico quase igual ao obtido após o acionamento da camada *RTO*, ou seja, muito próximo do ótimo econômico.

Os resultados promissores aliados à aprendizagem obtida nos desenvolvimentos e nas simulações apresentadas neste capítulo, favoreceram a escolha pela aplicação da estratégia implementada de acordo com a segunda abordagem em um problema diferente: O problema de controle e otimização econômica de um processo que ocorre dentro de um reator isotérmico, o qual foi obtido em um trabalho na literatura, estudado, implementado e utilizado como base de comparação. O desenvolvimento e os resultados obtidos neste novo processo são comparados com o trabalho original e estão apresentados no capítulo 5.

5 REATOR ISOTÉRMICO

ESTRUTURA APLICADA A UM REATOR ISOTÉRMICO

“Fluctuating petrochemical market prices make planning and scheduling vital to maximizing profits in the refining industry. The use of real-time optimization (RTO), a steady-state optimization of the targets/setpoints of the control system, carried out periodically (e.g., every hour), is very prevalent in the refining industry...”

Tsay et al. (2018)

Neste capítulo aplica-se a estratégia de integração proposta em um modelo de reação isotérmica. Este modelo também foi utilizado em (FERRAMOSCA et al., 2017), onde é submetido a um sistema de controle que inclui a questão econômica mas que no entanto é baseado em outra abordagem. Nas simulações do presente capítulo, motivado pelos bons resultados obtidos e apresentados no capítulo anterior, utilizou-se a abordagem de rastreamento econômico na subcamada *SSTO*, bem como a substituição do modelo fixo nas subcamadas *SSTO+GPC* por um modelo continuamente identificado. Os resultados obtidos com a abordagem *EMPC* no artigo são comparados com os resultados obtidos com a metodologia proposta.

5.1 REATOR ISOTÉRMICO

A estratégia de integração de camadas proposta foi aplicada no controle de um reator onde ocorrem reações isotérmicas compatíveis com reações de polimerização (LEE; BAILEY, 1980). Há duas vazões de alimentação do reator, compostas pelas substâncias P_0 e B respectivamente. Duas reações ocorrem ao mesmo tempo dentro do reator, onde estas duas substâncias reagem e produzem os produtos P_1 e P_2 conforme apresentado na figura 5.1. A vazão de saída do reator F_R é composta pelas frações do produtos P_1 e P_2 além do montante que não foi consumido das substâncias P_0 e B .




Figura 5.1: Diagrama do Reator isotérmico

Escolheu-se este processo para que se possa comparar a metodologia proposta com artigos acadêmicos da área. Ele foi utilizado em (FERRAMOSCA et al., 2017) aonde os autores investigam o desempenho de um controlador implementado dentro da abordagem *EMPC* (*Economic Model Predictive*), a qual tem forte orientação econômica e tem recebido

crescente atenção. Esta abordagem baseia-se no uso de controladores preditivos baseados em modelo, onde a informação econômica proveniente do *RTO* é adicionada de maneira apropriada na função de custo do controlador preditivo. A abordagem *EMPC* tem sido utilizada em trabalhos recentes, como por exemplo em (ANGELI et al., 2015), (RAWLINGS et al., 2012) e (FERRAMOSCA et al., 2017).

As equações de balanço de massa adimensional para a reação estão apresentadas na equação 5.1. Neste modelo, x_1, x_2, x_3 e x_4 representam respectivamente as concentrações de P_0, B, P_1 e P_2 na saída do reator. As entradas de controle u_1 e u_2 correspondem respectivamente à vazão de alimentação de P_0 e de B . Os parâmetros σ_1 e σ_2 representam as taxas das reações e são ajustados inicialmente com os valores de $\sigma_1 = 1$ e $\sigma_2 = 0.4$.

$$\begin{aligned} \dot{x}_1 &= +u_1 - x_1 - \sigma_1 x_1 x_2 \\ \dot{x}_2 &= +u_2 - x_2 - \sigma_1 x_1 x_2 - \sigma_2 x_2 x_3 \\ \dot{x}_3 &= -x_3 + \sigma_1 x_1 x_2 - \sigma_2 x_2 x_3 \\ \dot{x}_4 &= -x_4 + \sigma_2 x_2 x_3 \end{aligned} \quad (5.1)$$

Os valores das concentrações são limitados dentro da faixa de $0 \leq x_i \leq 10$ para $i = 1, 2, 3, 4$. As entradas também são limitadas dentro da faixa de $0 \leq u_i \leq 10$ para $i = 1, 2$.

5.2 ESTRATÉGIA RSGi APLICADA À REAÇÃO ISOTÉRMICA

As malhas de controle local e o controle supervisor são apresentados na figura 5.2.

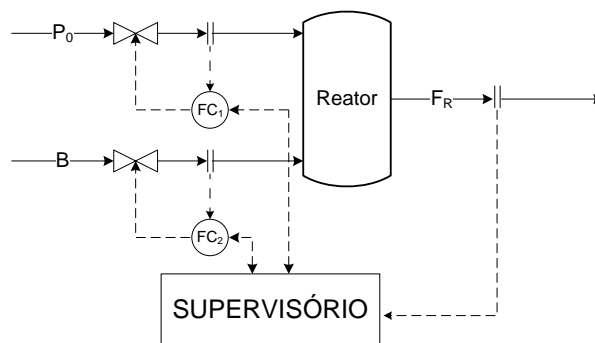


Figura 5.2: Malhas de controle

Como no artigo base de comparação, (FERRAMOSCA et al., 2017), os resultados são obtidos com controladores preditivos que controlam diretamente as variáveis do processo, para poder compará-los com o desempenho da estratégia proposta, despreza-se a dinâmica dos controladores locais, e admite-se que o mesmo ocorre aqui.

Nas simulações envolvendo a reação isotérmica, implementou-se a estrutura *RTO+SSTO+GPC* utilizando nos últimos dois o modelo cujos parâmetros são continuamente identificados *online*. A estrutura implementada é a mesma já apresentada anteriormente na figura 3.1.

A camada supervisória é constituída de duas subcamadas, *GPC* e *SSTO*, que compartilham o mesmo modelo identificado *online*, em suas versões dinâmica e estática. O modelo compartilhado por elas é um modelo 2×4 , no qual as entradas correspondem à vazão de alimentação P_0 e B , e as saídas correspondem às concentrações de P_0 , B , P_1 e P_2 na saída do reator. Para evitar possíveis danos ao desempenho do controlador causados pelo uso de um modelo não representativo, é utilizado um critério para permitir a substituição do modelo em uso, conforme apresentado no capítulo 3. A estrutura do modelo está apresentada na figura 5.3.




Figura 5.3: Estrutura do modelo utilizado no GPC

Inicialmente o controlador *GPC* utiliza um modelo médio identificado *offline*, de segunda ordem, enquanto a identificação de parâmetros corre em paralelo. Quando o erro de predição do modelo identificado cai abaixo de um valor pré-determinado, o modelo identificado substitui o modelo original. Desta forma o *GPC* não utiliza modelos que não representam o ponto de operação.

Nas simulações deste capítulo o *GPC* mantém a mesma função de custo, pois a estrutura de integração de controle não mudou. Sendo assim, a função de custo utilizada está apresentada na equação 5.2.

$$J_{GPC} = \sum_{k=1}^{HzPred} (y(k)_{GPC} - y_{SSTO}) + \sum_{k=1}^{HzCtrl} \Delta u(k)_{GPC} \quad (5.2)$$

Resta ainda, de acordo com a hierarquia apresentada na figura 2.5, a inclusão da subcamada e da camada de otimização, que corresponde à camada onde implementa-se o otimizador em tempo real. Utilizou-se no *RTO* a versão estacionária do modelo da reação isotérmica apresentada na equação 5.1 que é o mesmo modelo utilizado na simulação do processo, e que portanto, elimina a necessidade da etapa de reconciliação de dados. A

formulação do problema de otimização está apresentada na equação 5.3.

$$\begin{aligned}
 u_{RTO} &= \underset{u}{\operatorname{argmin}} -\Gamma_{RTO}(u, y, \rho) \\
 \text{s.a.} \\
 y &= ISO_{est}(u, \theta) \\
 y^{eq} &= y^S \\
 y^L &\leq y^{in} \leq y^U \\
 u^L &\leq u \leq u^U.
 \end{aligned} \tag{5.3}$$

onde $\Gamma_{RTO}(u, y, \rho)$ é a função econômica a ser minimizada, e $ISO_{est}(u, \theta)$ é a versão estacionária das equações 5.1. A função econômica utilizada pelo *RTO* para rastreamento do ponto ótimo de operação está apresentada na equação 5.4. Esta equação foi retirada de (FERRAMOSCA et al., 2017), onde os autores apresentam um desenvolvimento similar ao apresentado aqui.

$$\Gamma_{RTO}(u, y, \rho) = \rho_1 \cdot x_3 - \rho_2 \cdot (u_1 + u_2) \tag{5.4}$$

onde u_1 e u_2 representam as duas entradas do processo P_0 e B , x_3 é a concentração do produto P_1 , ρ_1 é o preço de venda associado ao produto P_1 , e ρ_2 representa o preço de compra das substâncias P_0 e B (ambas com o mesmo custo). A análise desta equação indica que, do ponto de vista do processo, o principal objetivo é maximizar a concentração de P_1 na vazão de saída do reator, e ao mesmo tempo minimizar o consumo das substâncias P_0 e B .

Ao final dos cálculos de otimização, os *setpoints* determinados pela camada *RTO* são intermediados pela subcamada *SSTO*. Nesta implementação utiliza-se a abordagem de rastreamento do ponto de ótimo econômico baseada no modelo mais simples continuamente identificado, conforme apresentado na equação 5.5.

$$\begin{aligned}
 u_{SSTO} &= \underset{u}{\operatorname{argmin}} -\Gamma_{SSTO}(u, y, \rho) \\
 \text{s.t.} \\
 y_{SSTO} &= A_s u_{SSTO} + d(t|t) \\
 y^{eq} &= y^S \\
 y^L &\leq y^{in} \leq y^U \\
 u^L &\leq u \leq u^U
 \end{aligned} \tag{5.5}$$

onde u_{SSTO} são os alvos para as entradas ajustados pela subcamada; y_{SSTO} são os alvos para as saídas que são obtidos através de $y_{SSTO} = A_s u_{SSTO} + d(t|t)$; $\Gamma_{SSTO}(u, y, \rho)$ é a função econômica apresentada na equação 5.6; A_s é a matriz de ganhos estáticos e $d(t|t)$ é a perturbação. Tanto A_s quanto $d(t|t)$ são os mesmos utilizados pelo *GPC*, garantindo assim que nas duas subcamadas, *SSTO* e *GPC*, os modelos são consistentes.

A função econômica utilizada na subcamada *SSTO* equivale à função econômica utilizada pelo *RTO*, porém com a adição de um termo extra que penaliza a distância do ponto de operação ao *setpoint* atual do *RTO*.

$$\Gamma_{SSTO}(u, y, \rho) = \rho_1 \cdot x_3 - \rho_2 \cdot (u_1 + u_2) - \|y - y_{RTO}^k\|_R^2 \quad (5.6)$$

onde u_1 e u_2 representam as duas entradas do processo P_0 e B , x_3 é a concentração do produto P_1 , ρ_1 é o preço de venda associado ao produto P_1 , e ρ_2 representa o preço de compra das substâncias P_0 e B (ambas com o mesmo custo), o termo y_{RTO}^k representa o *setpoint* atual do *RTO*, e R é um peso de ponderação ajustado para o valor de 0.1. Na solução da equação 5.6, a subcamada vai buscar dentro de uma região de proximidade a y_{RTO}^k , quais pontos de operação factíveis possuem o melhor resultado econômico.

É importante mencionar também que a subcamada possui o mesmo período de amostragem que o *GPC*, com uma frequência maior do que o acionamento do *RTO*. Isto permite responder mais rapidamente às possíveis perturbações econômicas que possam surgir.

5.3 RESULTADOS OBTIDOS COM A ESTRUTURA DE CONTROLE

Através da solução da função econômica do *RTO* (equação 5.4), obteve-se quatro pontos de operação ótimos, que estão apresentados na tabela 5.1, alinhados com os respectivos valores de ρ_1 e ρ_2 . O primeiro e o segundo são os mesmos que foram utilizados pelos autores em (FERRAMOSCA et al., 2017), enquanto o terceiro e quarto foram pensados para enaltecer os ganhos econômicos obtidos com a metodologia proposta. Além disso, o quarto ponto de operação é obtido com uma alteração adicional no parâmetro σ_2 , diminuindo o valor de 0.4 para 0.2. O motivo por trás desta alteração será explicado na terceira simulação.

Para poder validar a metodologia proposta efetuaram-se três estudos de simulações. No primeiro, a primeira simulação realizada por Ferramosca et al. (2017) é reproduzida e os seus resultados são comparados com os obtidos através da implementação da metodologia proposta. Compara-se especificamente o controlador nominal com a metodologia apresentada aqui, e também o custo de transição utilizando os mesmos dois métodos tal qual no artigo supracitado.

<i>PontoOp.</i>	ρ_1	ρ_2	x_1	x_2	x_3	x_4	u_1	u_2
1	7	1	4.9759	1.0097	3.5787	1.4454	10	7.4791
2	10	2	5.3813	0.8583	3.4383	1.1804	10	6.6573
3	50	1	4.0402	1.4751	3.7482	2.2116	10	9.6466
4*	20	3	4.0528	1.4674	4.5978	1.3494	10	8.7640

Tabela 5.1: Tabela com pontos de operação ótimos

No segundo estudo de simulações analisa-se a melhoria obtida pela introdução da subcamada *SSTO* quando comparada ao acionamento isolado de *GPC*, e também quando comparado com o acionamento de *RTO+GPC*, de maneira similar ao que foi feito no capítulo anterior, ressaltando o rastreamento econômico obtido com a metodologia proposta. E, finalmente, o terceiro conjunto de simulações que compara o desempenho da estrutura utilizando modelos fixos com o desempenho utilizando modelos variáveis continuamente identificados.

5.3.1 PRIMEIRA SIMULAÇÃO

Na primeira simulação, alteram-se os valores iniciais dos parâmetros $(\rho_1, \rho_2) = (7, 1)$, que correspondem ao primeiro ponto de operação da tabela, para $(\rho_1, \rho_2) = (10, 2)$ no instante $t = 10$, que correspondem ao segundo ponto de operação na tabela. Repete-se com esta substituição dos valores de ρ_1 e ρ_2 a simulação efetuada em (FERRAMOSCA et al., 2017). Pode-se dizer em outras palavras que o sistema sofre uma perturbação econômica no instante $t = 10$, enquanto toda a estrutura *RTO+GPC+SSTO* está ativa. A resposta do sistema a esta perturbação está apresentada na figura 5.4, onde representa-se em linha tracejada os *setpoints* ajustados pela estrutura, e em linha contínua a evolução das variáveis do sistema.




Figura 5.4: Primeira simulação - Resposta do sistema à perturbação econômica

A seguir, na figura 5.5, apresenta-se as entradas do sistema para a mesma simulação. Nota-se como a estrutura de controle atua nas entradas do sistema, gerando novas referências (em linha tracejada), para u_1 e u_2 .




Figura 5.5: Primeira Simulação - Evolução das entradas do sistema em resposta à perturbação econômica

Ressaltou-se em ambas figuras 5.4 e 5.5, os valores alcançados em regime permanente tanto para os estados x_1, x_2, x_3, x_4 quanto para as entradas u_1 e u_2 , de modo que eles possam ser comparados com os valores ótimos listados na tabela 5.1. Comparando-os com a tabela, fica claro que a estrutura proposta consegue trazer o sistema para muito próximo ao ponto de operação ótimo.

Quanto ao rendimento econômico, apresenta-se na figura 5.6 a evolução do retorno econômico ao longo da simulação. Nesta mesma figura em linha tracejada, está traçado o valor de referência da função econômica para cada ponto de operação, que no caso é de -7.5718 para o primeiro ponto de operação e -1.0680 para o segundo.




Figura 5.6: Primeira simulação - Valor ótimo f_{eco} x Valor atual f_{eco}

Para validar os resultados obtidos aqui, o desempenho econômico foi avaliado baseado no mesmo índice usado no artigo comparativo (FERRAMOSCA et al., 2017), que mensura o quanto a parte transitória da função econômica é diferente do valor da função econômica relativo ao respectivo ponto de operação. Este índice está apresentado na equação 5.7.

$$\Psi(\rho) = \sum_{k=0}^T |f_{eco}(x(k), u(k), \rho) - f_{eco}(x_{OPT}, u_{OPT}, \rho)| \quad (5.7)$$

onde $f_{eco}(x(k), u(k), \rho)$ é a função econômica calculada a cada instante na simulação, e $f_{eco}(x_{OPT}, u_{OPT}, \rho)$ é o valor de referência da função econômica relativo a cada ponto de operação. Valores menores de Ψ indicam, em geral, um rastreamento econômico melhor.

Em (FERRAMOSCA et al., 2017) os autores submeteram três controladores diferentes (*Nominal*, *Offset-Free*, *MultiModel*) a esta mesma simulação. Para cada uma delas, os autores calcularam o valor do índice da equação 5.7. Estes valores estão anotados na tabela 5.2 juntamente com o valor do índice calculado para a metodologia proposta, que é adicionado na final da tabela, com a sigla *RSGi* relativa a *RTO-SSTO-GPC-identified*, que é a estratégia proposta nesta tese.

Os resultados apresentados na tabela indicam que apenas um dos três controladores

	$\Psi(7, 1)$	$\Psi(10, 2)$
<i>Nominal</i>	300.16	614.75
<i>OffsetFree</i>	191.32	54.32
<i>MultiModel</i>	148.39	0.79
<i>RSGi</i>	151.38	17.68

Tabela 5.2: Índice Ψ calculado para a simulação 1

propostos em (FERRAMOSCA et al., 2017) consegue apresentar desempenho econômico superior ao *RSGi*. Entretanto, por ser baseado em uma estratégia multimodelos, o instante de chaveamento dos modelos pode causar instabilidade no controle do processo, o que não ocorre com a estratégia *RSGi* que suaviza as transições. A estratégia *RSGi* apresenta o segundo melhor desempenho em termos do índice Ψ , sendo bastante próximo para o ponto de operação $(7, 1)$, o que é um bom indicativo de um bom rastreamento econômico, atingindo assim um dos objetivos que a metodologia se propôs a atender. Outro objetivo importante é o de conseguir melhorar o tempo de reação a perturbações econômicas. Esta característica será tratada nos exemplos da segunda simulação.

Na segunda simulação, a estrutura é ativada camada por camada, de acordo com a seguinte sequência: 1 - GPC; 2 - SSTO+GPC; 3 - RTO+SSTO+GPC. Isto foi pensado para realçar o papel de cada camada no desempenho geral da estrutura.

5.3.2 SEGUNDA SIMULAÇÃO

Neste primeiro exemplo da segunda simulação, inicialmente o sistema se encontra no segundo ponto de operação, e no instante $t = 5$ ocorre uma perturbação econômica pois os valores dos custos são alterados de $(\rho_1, \rho_2) = (10, 2)$ para $(\rho_1, \rho_2) = (7, 1)$. A simulação consiste de três grandes momentos. No primeiro deles, apenas o *GPC* está acionado. Como pode ser notado nas figuras 5.7, 5.8 e 5.9, desde o instante $t = 5$ até o instante $t = 12$, o sistema não reage à perturbação econômica. No segundo momento, a subcamada *SSTO* é acionada no instante $t = 12$ e por consequência novas referências são determinadas e repassadas ao *GPC*, que por sua vez conduzirá o sistema na direção de um resultado econômico indicado pela solução da equação 5.6. No terceiro momento, que ocorre a partir do instante $t = 27$, a camada *RTO* é acionada. Neste momento, novos *setpoints* são repassados ao *GPC* que por sua vez conduz o sistema para o ponto de ótimo retorno econômico. Desta maneira, do instante $t = 12$ até o instante $t = 27$, a metodologia proposta mostrou-se efetiva em melhorar o desempenho econômico entre os instantes de amostragem do *RTO*.

A evolução das entradas do processo está apresentada na figura 5.7, aonde as linhas

tracejadas representam os *setpoints* e as linhas sólidas representam as entradas u_1 e u_2 .




Figura 5.7: Segunda Simulação - Ex.1 - Evolução das entradas do sistema

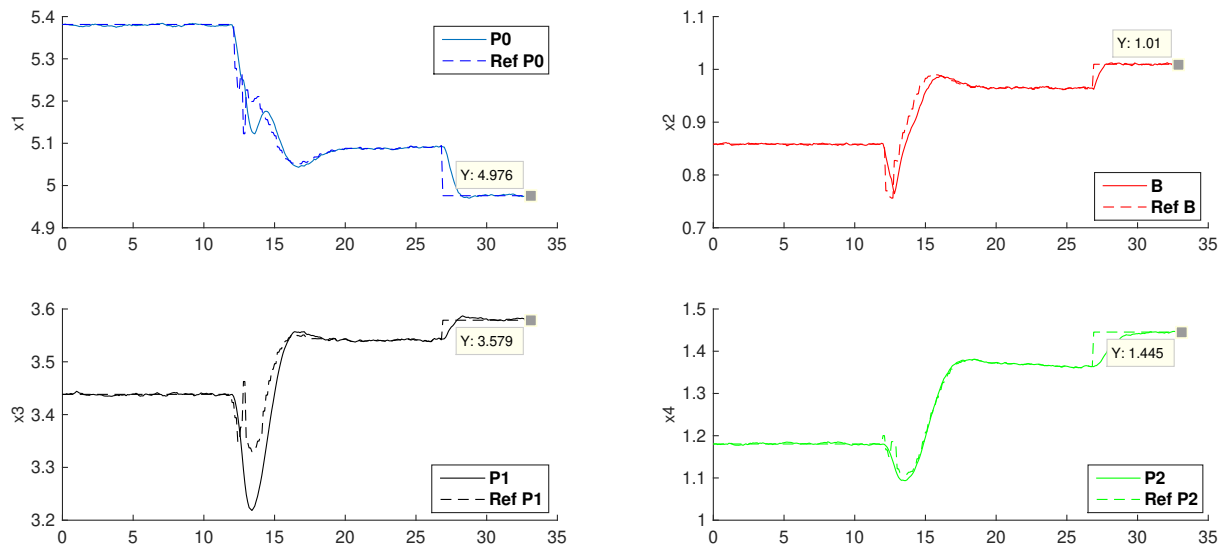


Figura 5.8: Segunda simulação - Ex.1 - Resposta do sistema à perturbação econômica

Nesta simulação, como a perturbação econômica é pequena, o ganho obtido pelo acionamento da subcamada *SSTO* também é pequeno. Entretanto, a evolução das saídas do sistema mostra que a concentração de P_1 aumentou por consequência da atuação da subcamada o que, lembrando dos objetivos de maximizar P_1 e minimizar u_1 e u_2 , representa uma melhoria. O *GPC* sozinho não produziu esta alteração, o que pode ser notado entre os instantes $t = 5$ até $t = 12$. A evolução do desempenho econômico está apresentada na figura 5.9.

Importante também ressaltar que as saídas controladas se mantiveram estáveis durante toda a simulação, e que as variáveis controladas atingiram os valores apresentados na tabela 5.1 sem *offsets*.

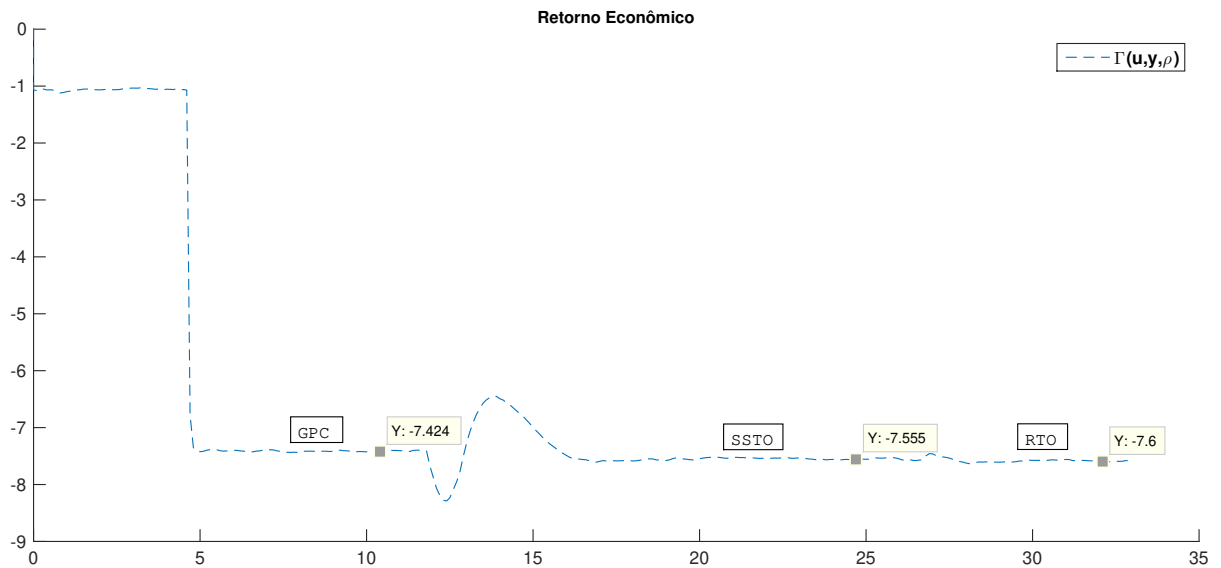


Figura 5.9: Segunda simulação - Ex.1 - Evolução do retorno econômico

5.3.3 SEGUNDA SIMULAÇÃO - EXEMPLO 2

Neste exemplo o processo estará inicialmente no mesmo ponto de operação que no exemplo anterior, mas os custos serão agora alterados no instante $t = 5$ para $(\rho_1, \rho_2) = (50, 1)$, que corresponde ao terceiro ponto de operação na tabela 5.1, causando uma perturbação econômica muito maior. Submete-se o sistema aos mesmos passos, começando com apenas o *GPC* acionado, acionando-se a subcamada *SSTO* em $t = 12$ e a camada *RTO* em $t = 27$. Novamente o sistema somente começará a reagir a partir do acionamento da subcamada *SSTO*, como pode ser visto na figura 5.10.




Figura 5.10: Segunda simulação - Ex.2 - Evolução das entradas do sistema

É interessante perceber que nesta simulação a subcamada conseguiu direcionar o

sistema a um ponto de operação que é muito próximo do ponto ótimo determinado pelo *RTO* (apresentado na tabela 5.1). A evolução das saídas do processo estão apresentadas na figura 5.11, onde a atuação da subcamada *SSTO* é bastante evidente, aumentando a produção de P_1 , e melhorando também o retorno econômico, que desta vez é mais evidente dada a magnitude da perturbação, como pode ser notado na figura 5.12.

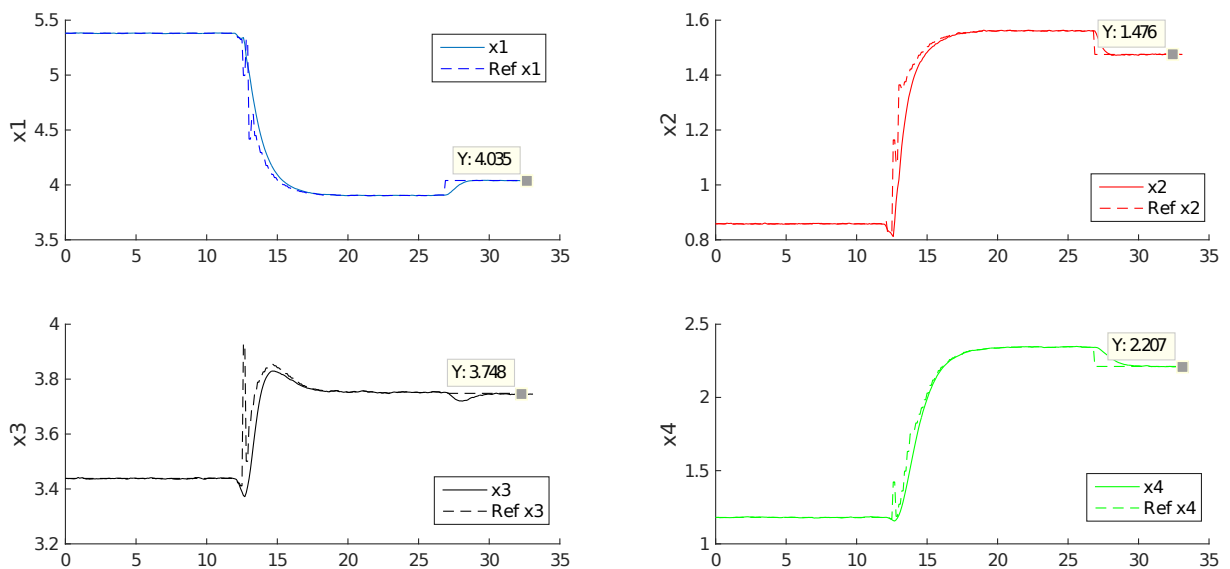


Figura 5.11: Segunda simulação - Ex.2 - Resposta do sistema à perturbação econômica

O gráfico de retorno econômico é ampliado para ressaltar o ganho obtido pelo acionamento da subcamada no instante $t = 12$. É claro que o ganho obtido entre os instantes $t = 12$ e $t = 27$ não teriam ocorrido se o sistema fosse composto apenas pela estrutura *RTO+MPC*.




Figura 5.12: Segunda simulação - Evolução do retorno econômico

5.3.4 TERCEIRA SIMULAÇÃO

Na terceira simulação, modifica-se intencionalmente o processo ao se alterar o a taxa de reação σ_2 de 0.4 para 0.2. Efetuam-se dois ensaios, cada qual com um modelo diferente. No primeiro ensaio, utiliza-se um modelo médio fixo na camada Supervisório, que como já foi dito, é composta pelas subcamadas *SSTO* e *GPC*. O modelo é identificado *offline* e uma vez definidos seus parâmetros, o ensaio inteiro é feito com este modelo sem alterações. No segundo ensaio utiliza-se na camada Supervisório um modelo variável, cujos parâmetros são continuamente identificados ao longo do ensaio através dos dados das variáveis. A terceira simulação é pensada para contrastar o desempenho do sistema baseado em modelo fixo com o sistema baseado em modelo variável, principalmente quando o processo controlado sofre alterações.

Submeteu-se os dois ensaios ao mesmo passo a passo. No instante $t = 5$, além da alteração na taxa de reação para $\sigma_2 = 0.2$, alteram-se os custos de $(\rho_1, \rho_2) = (10, 2)$ para $(\rho_1, \rho_2) = (20, 3)$. O ponto de operação ótimo neste cenário está apresentado na quarta linha da tabela 5.1. Uma vez mais o sistema está inicialmente controlado apenas pelo *GPC* até o instante $t = 12$ quando aciona-se a subcamada *SSTO*, e posteriormente, no instante $t = 27$ aciona-se o *RTO*.

Nas figuras 5.13 e 5.14, apresenta-se a evolução das saídas do processo para o sistema baseado em modelo fixo e para o sistema baseado em modelo variável respectivamente. O sistema reage no instante $t = 5$ à variação de σ_2 pois esta perturbação não é econômica e portanto é percebida pelo *GPC*. Os dois ensaios são muito parecidos até este instante, mas do instante $t = 12$ até o instante $t = 27$, a subcamada *SSTO* é ativada e as diferenças entre cada ensaio começam a se intensificar. Obtém-se uma produção maior de P_1 no segundo ensaio, no entanto o ensaio baseado em modelo fixo apresenta uma resposta mais comportada das saídas, com muito pouco *overshoot*. A resposta do sistema baseado em modelo continuamente identificado é um pouco menos comportada, pois sempre que o sistema está em alguma transição, o modelo está sendo alterado e o rastreamento econômico causará algum movimento errático. Esta característica pode ser considerada uma desvantagem da metodologia proposta. Ainda assim, ambos ensaios conseguiram atingir os pontos ótimos sem ocorrência de *offsets*.

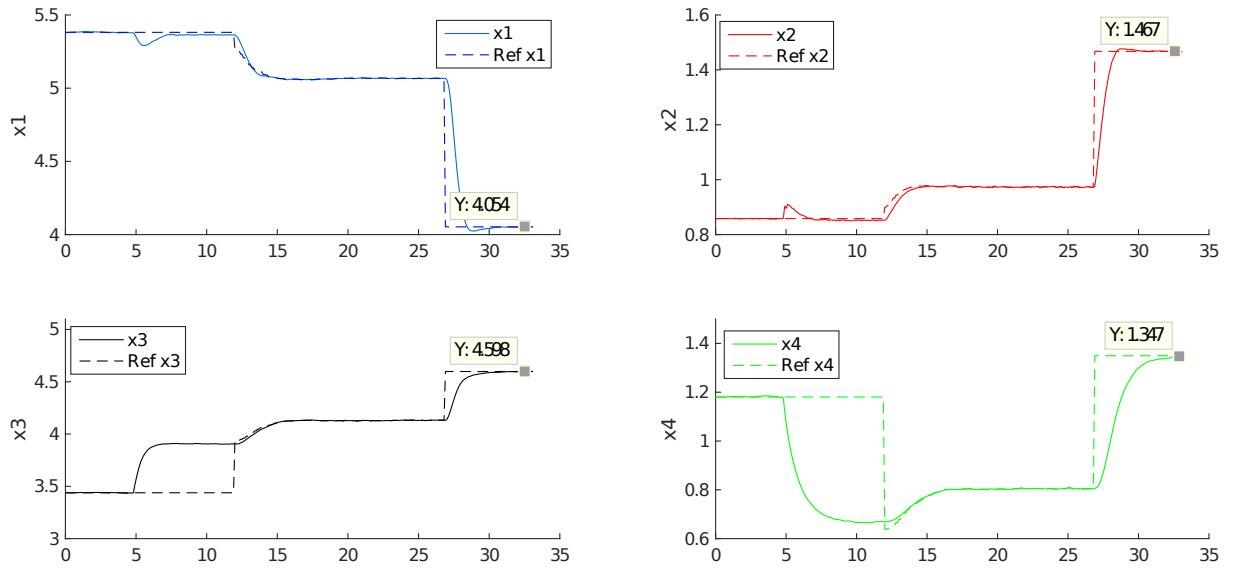


Figura 5.13: Terceira simulação - Modelo Fixo - Resposta do sistema à perturbação econômica

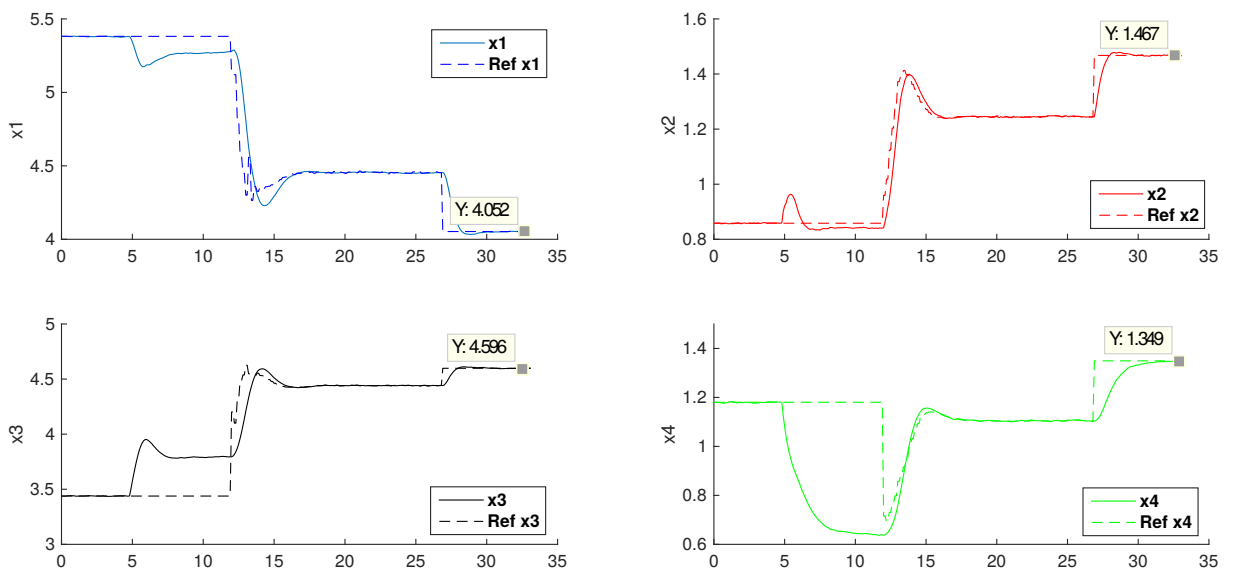


Figura 5.14: Terceira simulação - Modelo Variável - Resposta do sistema à perturbação econômica

Comparando-se agora o retorno econômico de cada ensaio, apresenta-se nas figuras 5.15 e 5.16 o retorno do ensaio com modelo fixo e com modelo variável respectivamente. O acionamento da subcamada *SSTO* no segundo ensaio trouxe um retorno econômico maior, em torno de 35.15, enquanto no primeiro ensaio o retorno ficou em torno de 32.55. Isto representa um retorno aproximadamente 10% maior no segundo ensaio, e um valor absoluto muito próximo do ótimo econômico obtido com o *RTO* que tem um valor em torno de 35.62. A metodologia proposta, também neste conjunto de ensaios, consegue aumentar o retorno econômico entre instantes de amostragem do *RTO*.




Figura 5.15: Terceira Simulação - Modelo Fixo - Evolução do retorno econômico




Figura 5.16: Terceira Simulação - Modelo Variável - Evolução do retorno econômico

5.4 DISCUSSÕES

Em todos os três exemplos apresentados neste capítulo, o *GPC* sozinho foi incapaz de reagir a quaisquer perturbações econômicas a que o sistema tenha sido submetido. E cabe ressaltar que, se a perturbação for grande, manter o sistema inerte não é uma boa estratégia pois o resultado econômico será bastante prejudicado. A metodologia proposta mostrou ser capaz de reagir às perturbações econômicas sem abrir mão da estabilidade e controlabilidade. No artigo utilizado como base de comparação para as simulações, os autores propuseram três controladores dentro da abordagem *EMPC*. O primeiro deles, baseado no modelo nominal sem considerações de robustez, é incapaz de atingir os pontos ótimos econômicos; o segundo, baseado numa estratégia *offset-free* consegue atingir os pontos ótimos econômicos, mas as saídas oscilam em torno dos mesmos; o terceiro, baseado em uma estratégia multi-modelos, é capaz de levar o sistema aos pontos ótimos econômicos, sem ocorrências de *offsets* e mantendo o sistema estável. A metodologia de integração proposta obtém resultados semelhantes ao terceiro controlador, com a vantagem que pode ser aplicada em qualquer região de operação por causa da identificação, enquanto a abordagem multi-modelos perde desempenho em pontos de operação que não correspondem aos modelos do conjunto.

6 CONCLUSÃO

DISCUSSÕES E CONCLUSÕES

“Process manufacturing plants presently compete in an increasingly global arena, with increased competition, reduced profit margins, increased utility costs, and increased variability in market conditions, creating a dynamic operating environment... Such conditions limit the performance of traditional RTO methods due to the requirement for the system to be at steady state before successive RTO executions, motivating the development of economic optimization approaches in which process dynamics are considered.”

Jamaludin et al. (2017)

Apresenta-se a seguir a conclusão do trabalho de desenvolvimento da estratégia de integração proposta. Os objetivos iniciais do trabalho são copiados aqui para facilitar a comparação do que foi proposto com o que foi atingido:

- Desenvolver e implementar algoritmos de controle dentro de uma estrutura hierárquica de controle.
- Propor e implementar uma solução original de integração entre as camadas inferiores.
- Avaliar e comparar o desempenho econômico da solução original com soluções encontradas na literatura.
- Desenvolver e implementar um modelo dinâmico de uma reação química padrão da área para servir de *test-bed* aos modelos e algoritmos propostos.

O trabalho apresentou inicialmente como objetivos a serem alcançados, propor uma estratégia combinada de identificação, controle e otimização, dentro de uma estrutura hierárquica de controle, que fosse facilmente implementável, e que permitisse melhorar o desempenho da estrutura sem trazer riscos à operação.

Após uma revisão bibliográfica bastante abrangente, onde estudou-se diversas abordagens possíveis para fazer a implementação de otimização combinada a sistemas de controle, dentro de uma estrutura hierárquica padrão do ambiente industrial, optou-se pela inclusão de uma subcamada intermediária entre as camadas *RTO* e *GPC*.

Os relatos na literatura de perda de desempenho do controlador, quando uma estrutura hierárquica de controle submete o sistema a um ponto de operação distante do ponto de linearização do modelo, subsidiaram a escolha pelos modelos continuamente identificáveis, localmente representativos.

A opção pela inclusão da subcamada, em conjunto com a opção de utilizar modelos continuamente identificáveis, levou a idealização de uma estratégia de integração que contivesse estas duas características, e que também pudesse ser de fácil integração aos processos industriais. Neste sentido, descartaram-se, intencionalmente, alternativas baseadas em redes neurais, ou em modelos não lineares como *Hammerstein*, ou *Wiener*, por exemplo, por se entender que apesar de bastante promissoras o uso destas alternativas ainda não se encontram maduras em ambiente industrial. Até onde se conhece, acredita-se que a estratégia de integração proposta seja original.

Para avaliar o desempenho da estratégia de integração proposta, dois processos químicos foram escolhidos para servir de *test-bed*. O primeiro deles, um modelo versátil

de um processo químico, através do qual é possível simular diversas situações que ocorrem em processos industriais, e o segundo um modelo de um processo de reações isotérmicas compatíveis com reações de polimerização.

O primeiro modelo, processo de *Otto*, foi utilizado tendo por foco maior o estudo e desenvolvimento da estratégia, a apreensão dos conhecimentos necessários para implementar a mesma, a comparação das duas abordagens diferentes para implementação da subcamada, e para observar as consequências dos parâmetros de ajuste no comportamento do sistema. Foram feitas quatro simulações ao todo da estratégia aplicada a este modelo, realçando o que cada camada influencia na resposta do sistema. Em todos os ensaios a utilização da subcamada suaviza a transição dos *setpoints*, mantendo o sistema controlado e sem ocorrência de *offsets*. Entretanto, a comparação do resultado das duas abordagens de implementação da subcamada indicam que aquela que contém o rastreamento ativo do ponto econômico traz mais vantagens, quando confrontada com as diferentes perturbações.

Após ter dominado a implementação da estratégia, esta foi aplicada na simulação da reação de polimerização. No artigo original, que é base de comparação de resultados, submeteu-se este mesmo processo a três abordagens diferentes de controladores preditivos com ênfase econômica, conhecidos por *EMPC*. Os resultados obtidos pela estratégia de integração proposta foram similares aos resultados obtidos pela abordagem que atingiu melhor desempenho. Os resultados obtidos com este conjunto de simulações, e as comparações com os resultados obtidos no artigo original, fizeram parte do artigo publicado na revista *Journal of Control, Automation and Electrical System*, citado na bibliografia como (POZAS; ARRUDA, 2018)

Todos os objetivos propostos inicialmente foram atingidos, porém nem todas as possibilidades de investigação e pesquisa foram abordadas. Apresenta-se a seguir as perspectivas de trabalho futuras.

6.1 PERSPECTIVAS E TRABALHOS FUTUROS

O desenvolvimento de um trabalho de doutorado ao invés de fornecer todas as respostas, acaba por suscitar novas e instigantes perguntas. Sendo assim, o presente trabalho destaca algumas possibilidades de continuidade da pesquisa:

- Aprimorar o processo de identificação integrando alguma estratégia de robustez;
- Aplicação da estratégia *RSGi* em um processo com forte característica não-linear. Avalia-se neste momento a possibilidade de utilização em sistemas de controle de qualidade de

água.

- Implementar a estratégia com controladores *PI* auto-sintonizáveis, e avaliar as interferências e a coordenação dos dois processos de identificação (*GPC* e *PI*).

Acredita-se que seja possível então obter bons resultados com a aplicação da estratégia nestas situações, e continuar a aprimorar o desenvolvimento da estratégia.

REFERÊNCIAS

- ADETOLA, V.; GUAY, M. Integration of real-time optimization and model predictive control. **Journal of Process Control**, v. 20, n. 2, p. 125 – 133, 2010. ISSN 0959-1524. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0959152409001632>.
- ALVAREZ, L. A.; ODLOAK, D. Robust integration of real time optimization with linear model predictive control. **Computers & Chemical Engineering**, v. 34, n. 12, p. 1937 – 1944, 2010. ISSN 0098-1354. 10th International Symposium on Process Systems Engineering, Salvador, Bahia, Brasil, 16-20 August 2009. Disponível em: <http://www.sciencedirect.com/science/article/pii/S009813541000222X>.
- ANGELI, D.; CASAVOLA, A.; TEDESCO, F. Theoretical advances on economic model predictive control with time-varying costs. **IFAC-PapersOnLine**, v. 48, n. 23, p. 272 – 277, 2015. ISSN 2405-8963. 5th IFAC Conference on Nonlinear Model Predictive Control NMPC 2015.
- ARRUDA, L. V. R. d.; SWIECH, M. C. S.; NEVES-JR, F.; DELGADO, M. R. Um método evolucionário para sintonia de controladores pi/pid em processos multivariáveis. **Sba: Controle & Automação. Sociedade Brasileira de Automática**, sciELO, v. 19, p. 1 – 17, 03 2008. ISSN 0103-1759. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592008000100001nrm=iso.
- BACKX, T.; BOSGRA, O.; MARQUARDT, W. Integration of model predictive control and optimization of processes: Enabling technology for market driven process operation. **IFAC Proceedings Volumes**, v. 33, n. 10, p. 249 – 260, 2000. ISSN 1474-6670. IFAC Symposium on Advanced Control of Chemical Processes 2000, Pisa, Italy, 14-16 June 2000.
- BAGHERI, P.; SEDIGH, A. K. Analytical approach to tuning of model predictive control for first-order plus dead time models. **IET Control Theory Applications**, v. 7, n. 14, p. 1806–1817, September 2013. ISSN 1751-8644.
- BARTUSIAK, R. NLMPCC: A platform for optimal control of feed- or product-flexible manufacturing. In: FINDEISEN, R.; ALLGOWER, F.; BIEGLER, L. (Ed.). **Assessment and Future Directions of Nonlinear Model Predictive Control**. [S.l.]: Springer Berlin Heidelberg, 2007, (Lecture Notes in Control and Information Sciences, v. 358). p. 367–381. ISBN 978-3-540-72698-2.
- BONVIN, D. Special issue real-time optimization of processes. **Processes**, v. 5, n. 2, 2017. ISSN 2227-9717. Disponível em: <http://www.mdpi.com/2227-9717/5/2/27>.
- BORDONS, C.; CAMACHO, E. F. A generalized predictive controller for a wide class of industrial processes. **IEEE Transactions on Control Systems Technology**, v. 6, n. 3, p. 372–387, May 1998. ISSN 1063-6536.
- BROSILOW, B. J. C. **Techniques of Model-Based Control Int**. [S.l.]: Prentice Hall, 2002.

CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. 1st. ed. London, UK: Springer-Verlag, 1999. 294 p. ISBN 3540762418.

CHACHUAT, B.; SRINIVASAN, B.; BONVIN, D. Adaptation strategies for real-time optimization. **Computers & Chemical Engineering**, v. 33, n. 10, p. 1557 – 1567, 2009. ISSN 0098-1354. Selected Papers from the 18th European Symposium on Computer Aided Process Engineering (ESCAPE-18). Disponível em: <http://www.sciencedirect.com/science/article/pii/S0098135409001082>).

CLARKE, D.; MOHTADI, C.; TUFFS, P. Generalized predictive control - part ii extensions and interpretations. **Automatica**, v. 23, n. 2, p. 149 – 160, 1987. ISSN 0005-1098.

CLARKE, D.; MOHTADI, C.; TUFFS, P. Generalized predictive control. part i - the basic algorithm. **Automatica**, v. 23, n. 2, p. 137 – 148, 1987. ISSN 0005-1098. Disponível em: <http://www.sciencedirect.com/science/article/pii/0005109887900872>).

CUTLER, C.; PERRY, R. Real time optimization with multivariable control is required to maximize profits. **Computers & Chemical Engineering**, v. 7, n. 5, p. 663–667, jan. 1983. ISSN 00981354. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/0098135483800106>).

CUTLER, C.; RAMAKER, B. Dynamic matrix control - a computer control algorithm. **Aiche National Mtg.**, Houston, Tx, 1979.

DARBY, M. L.; NIKOLAOU, M. MPC: Current practice and challenges. **Control Engineering Practice**, v. 20, n. 4, p. 328 – 342, 2012. ISSN 0967-0661. Special Section: {IFAC} Symposium on Advanced Control of Chemical Processes - {ADCHEM} 2009. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0967066111002528>).

DARBY, M. L.; NIKOLAOU, M.; JONES, J.; NICHOLSON, D. RTO: An overview and assessment of current practice. **Journal of Process Control**, v. 21, n. 6, p. 874 – 884, 2011. ISSN 0959-1524. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0959152411000540>).

DEKEYSER, R.; CAUWENBERGHE, A. V. Extended prediction self-adaptive control. In: 7th. IFAC SIMP. ON IDENT. AND SYST. PARAMETER ESTIMATION. York, 1985. p. 1255–1260.

ENGELL, S. Feedback control for optimal process operation. **Journal of Process Control**, v. 17, n. 3, p. 203–219, 2007.

FERRAMOSCA, A.; GONZALEZ, A. H.; LIMON, D. Offset-free multi-model economic model predictive control for changing economic criterion. **Journal of Process Control**, v. 54, n. Supplement C, p. 1 – 13, 2017. ISSN 0959-1524. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0959152417300409>).

FINDEISEN, W. et al. **Control and coordination in hierarchical systems**. Belfast, Ireland: John Wiley & Sons, 1980. v. 27. 480 p. ISSN 0018-9286. ISBN 0471277428.

FORBES, J.; MARLIN, T. Design cost: a systematic approach to technology selection for model-based real-time optimization systems. **Computers and Chemical Engineering**, Elsevier Science, v. 20, n. 6-7, p. 717–734, 1996.

FRIEDMAN. Closed-loop optimization update—a step closer to fulfilling the dream. **Hydrocarbon Processing**, v. 79, n. 1, p. 15, 2000. ISSN 00188190.

GATTU, G.; PALAVAJHALA, S.; ROBERTSON, D. B. Are oil refineries ready for non-linear control and optimization? In: INTERNATIONAL SYMPOSIUM ON PROCESS SYSTEMS ENGINEERING AND CONTROL. [S.l.], 2003.

GOPALAKRISHNAN, A.; BIEGLER, L. T. Economic nonlinear model predictive control for periodic optimal operation of gas pipeline networks. **Computers & Chemical Engineering**, v. 52, p. 90 – 99, 2013. ISSN 0098-1354. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0098135412003778>.

HINOJOSA, A. I.; FERRAMOSCA, A.; GONZALEZ, A. H.; ODLOAK, D. One-layer gradient-based mpc+rto of a propylene/propane splitter. **Computers & Chemical Engineering**, v. 106, p. 160 – 170, 2017. ISSN 0098-1354. ESCAPE-26.

HOU, Y.; WU, J.; CHEN, Y. Online steady state detection based on rao-blackwellized sequential monte carlo. **Quality and Reliability Engineering International**, v. 32, n. 8, p. 2667–2683, 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2067>.

JAMALUDIN, M. Z.; LI, H.; CHRISTOPHER, L. E. S. The utilization of closed-loop prediction for dynamic real-time optimization. **The Canadian Journal of Chemical Engineering**, v. 95, n. 10, p. 1968–1978, 2017. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/cjce.22927>.

JIANG, T.; CHEN, B.; HE, X.; STUART, P. Application of steady-state detection method based on wavelet transform. **Computers & Chemical Engineering**, v. 27, n. 4, p. 569–578, 2003. ISSN 0098-1354. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0098135402002351>.

JOHANSEN, T.; SBARBARO, D. Lyapunov-based optimizing control of nonlinear blending processes. **Control Systems Technology, IEEE Transactions on**, v. 13, n. 4, p. 631–638, July 2005. ISSN 1063-6536.

KALMAN, R. A new approach to linear filtering and prediction problems. **Transactions of the ASME - Journal of basic Engineering**, v. 82, p. 35–45, 01 1960.

KASSMANN, D. E.; BADGWELL, T. A.; HAWKINS, R. B. Robust steady-state target calculation for model predictive control. **AIChE Journal**, Wiley Subscription Services, Inc., A Wiley Company, v. 46, n. 5, p. 1007–1024, 2000. ISSN 1547-5905. Disponível em: <http://dx.doi.org/10.1002/aic.690460513>.

ŁAWRYŃCZUK, M. Online set-point optimisation cooperating with predictive control of a yeast fermentation process: A neural network approach. **Engineering Applications of Artificial Intelligence**, v. 24, n. 6, p. 968 – 982, 2011. ISSN 0952-1976. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0952197611000674>.

LEE, C. K.; BAILEY, J. E. Modification of consecutive-competitive reaction selectivity by periodic operation. **Industrial & Engineering Chemistry Process Design and Development**, v. 19, n. 1, p. 160–166, 1980. Disponível em: <https://doi.org/10.1021/i260073a028>.

LIPTAK, B. G.; BERNANRD, J. W.; WILLIAMS, T. J. Hierarchical control. In: **Instrument Engineers' Handbook, Fourth Edition, Volume Two: Process Control and Optimization**. 4th. ed. Boca Raton, FL: Taylor & Francis, 2005, (Instrument Engineers' Handbook, v. 2). p. 193–204. ISBN 9781420064001.

LJUNG, L. **System Identification: Theory for the User**. Prentice Hall PTR, 1999. (Prentice Hall information and system sciences series). ISBN 9780136566953. Disponível em: <https://books.google.com.br/books?id=nHFoQgAACAAJ>.

MARCHETTI, A.; FERRAMOSCA, A.; GONZALEZ, A. Steady-state target optimization designs for integrating real-time optimization and model predictive control. **Journal of Process Control**, v. 24, n. 1, p. 129 – 145, 2014. ISSN 0959-1524. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0959152413002291>.

MCLEAN, C. R.; JONES, A. T.; BUREAU, N. A Proposed Hierarchical Control Model for Automated Manufacturing Systems. **Journal of Manufacturing Systems**, v. 5, n. 1, p. 15–25, 1986.

MORARI, M.; ARKUN, Y.; STEPHANOPOULOS, G. Studies in the synthesis of control structures for chemical processes: Part i: Formulation of the problem. process decomposition and the classification of the control tasks. analysis of the optimizing control structures. **AIChE Journal**, American Institute of Chemical Engineers, v. 26, n. 2, p. 220–232, 1980. ISSN 1547-5905. Disponível em: <http://dx.doi.org/10.1002/aic.690260205>.

OGATA, K. **Modern Control Engineering**. 4th. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 2001. ISBN 0130609072.

PETERSEN, L. N.; POULSEN, N. K.; NIEMANN, H. H.; UTZEN, C.; JØRGENSEN, J. B. Comparison of three control strategies for optimization of spray dryer operation. **Journal of Process Control**, v. 57, p. 1 – 14, 2017. ISSN 0959-1524.

POZAS, L. F.; ARRUDA, L. Valéria Ramos de. A new approach to integrate ssto, mpc and rto using online identified models: Use of updated models to smooth integration. **Journal of Control, Automation and Electrical Systems**, v. 29, 07 2018.

QIN, S.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control Engineering Practice**, v. 11, n. 7, p. 733 – 764, 2003. ISSN 0967-0661.

RAO, C. V.; RAWLINGS, J. B. Steady states and constraints in model predictive control. **AIChE Journal**, Wiley Subscription Services, Inc., A Wiley Company, v. 45, n. 6, p. 1266–1278, 1999. ISSN 1547-5905. Disponível em: <http://dx.doi.org/10.1002/aic.690450612>.

RAWLINGS, J. Tutorial overview of model predictive control. **Control Systems, IEEE**, v. 20, n. 3, p. 38–52, Jun 2000. ISSN 1066-033X.

RAWLINGS, J. B.; ANGELI, D.; BATES, C. N. Fundamentals of economic model predictive control. In: **2012 IEEE 51st IEEE Conference on Decision and Control (CDC)**. [S.l.: s.n.], 2012. p. 3851–3861. ISSN 0191-2216.

REVOLLAR, S.; VEGA, P.; VILANOVA, R. Economic optimization of wastewater treatment plants using non linear model predictive control. In: **System Theory, Control and Computing (ICSTCC), 2015 19th International Conference on**. [S.l.: s.n.], 2015. p. 583–588.

RICHALET, J.; RAULT, A.; TESTUD, J.; PAPON, J. Model predictive heuristic control: Applications to industrial processes. **Automatica**, v. 14, n. 5, p. 413 – 428, 1978. ISSN 0005-1098. Disponível em: <http://www.sciencedirect.com/science/article/pii/0005109878900018>).

SEQUEIRA, S. E.; GRAELLS, M.; PUIGJANER, L. Real-time evolution for on-line optimization of continuous processes. **Industrial & Engineering Chemistry Research**, v. 41, n. 7, p. 1815–1825, 2002. Disponível em: <https://doi.org/10.1021/ie010464l>).

SHEAD, L. R. E.; MUSKE, K. R.; ROSSITER, J. A. Adaptive steady-state target optimization using iterative modified gradient-based methods in linear non-square mpc. In: **2009 American Control Conference**. [S.l.: s.n.], 2009. p. 2558–2563. ISSN 0743-1619.

SIMON, H. A. The architecture of complexity. In: _____. **Facets of Systems Science**. Boston, MA: Springer US, 1991. p. 457–476. ISBN 978-1-4899-0718-9. Disponível em: https://doi.org/10.1007/978-1-4899-0718-9_31).

SINGH, A.; FORBES, J.; VERMEER, P.; WOO, S. Model-based real-time optimization of automotive gasoline blending operations. **Journal of Process Control**, v. 10, n. 1, p. 43 – 58, 2000. ISSN 0959-1524. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0959152499000372>).

SKOGESTAD, S. Plantwide control: the search for the self-optimizing control structure. **Journal of Process Control**, v. 10, n. 5, p. 487–507, out. 2000. ISSN 09591524. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/S0959152400000238>).

SOUZA, G. D.; ODLOAK, D.; ZANIN, A. C. Real time optimization (rto) with model predictive control (mpc). **Computers & Chemical Engineering**, v. 34, n. 12, p. 1999 – 2006, 2010. ISSN 0098-1354. 10th International Symposium on Process Systems Engineering, Salvador, Bahia, Brasil, 16-20 August 2009. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0098135410002498>).

TATJEWSKI, P. Advanced control and on-line process optimization in multilayer structures. **Annual Reviews in Control**, v. 32, n. 1, p. 71 – 85, 2008. ISSN 1367-5788. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1367578808000084>).

TATJEWSKI, P.; ŁAWRYŃCZUK, M.; MARUSAK, P. M. Linking nonlinear steady-state and target set-point optimisation for model predictive control. In: **IEE International Control Conference ICC 2006**. [S.l.: s.n.], 2006. CD, p. 1–6.

TSAY, C.; PATTISON, R. C.; PIANA, M. R.; BALDEA, M. A survey of optimal process design capabilities and practices in the chemical and petrochemical industries. **Computers & Chemical Engineering**, 2018. ISSN 0098-1354. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0098135418300231>).

WILLIAMS, T. J.; OTTO, R. E. A generalized chemical processing model for the investigation of computer control. **American Institute of Electrical Engineers, Part I: Communication and Electronics, Transactions of the**, v. 79, n. 5, p. 458–473, Nov 1960. ISSN 0097-2452.

WU, S. D.; WYSK, R. A. Scheduling, optimization and control in automated systems. In: LEONDES, C. (Ed.). **Manufacturing and Automation Systems: Techniques and Technologies, Part 3 of 5**. Academic Press, 1991, (Control and Dynamic Systems,

v. 47). p. 51 – 76. Disponível em: <http://www.sciencedirect.com/science/article/pii/B978012012747450007X>).

XIE, S.; YANG, C.; WANG, X.; YUAN, X.; XIE, Y. A data-driven adaptive multivariate steady state detection strategy for the evaporation process of the sodium aluminate solution. **Journal of Process Control**, v. 68, p. 145 – 159, 2018. ISSN 0959-1524. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0959152418301136>).

YING, C.-M.; JOSEPH, B. Performance and stability analysis of lp-mpc and qp-mpc cascade control systems. **AIChE Journal**, Wiley Subscription Services, Inc., A Wiley Company, v. 45, n. 7, p. 1521–1534, 1999. ISSN 1547-5905. Disponível em: <http://dx.doi.org/10.1002/aic.690450714>).

APÊNDICE A - EQUAÇÕES DINÂMICAS DA REAÇÃO OTTO

EQUAÇÕES DE BALANÇO DE MASSA

$$\frac{dA_R}{dt} = \frac{F_A}{V_R} + \frac{F_L}{V_R}(A_L) - \frac{F_R}{V_R}(A_R) - k_1(A_R)(B_R)$$

$$\frac{dB_R}{dt} = \frac{F_B}{V_R} + \frac{F_L}{V_R}(B_L) - \frac{F_R}{V_R}(B_R) - k_1(A_R)(B_R) - k_2(B_R)(C_R)$$

$$\frac{dC_R}{dt} = \frac{F_C}{V_R}(C_L) - \frac{F_R}{V_R}(C_R) + 2k_1(A_R)(B_R) - 2k_2(B_R)(C_R) - k_3(C_R)(P_R)$$

$$\frac{dE_R}{dt} = \frac{F_E}{V_R}(E_L) - \frac{F_R}{V_R}(E_R) + 2k_2(B_R)(C_R)$$

$$\frac{dG_R}{dt} = 1.5k_3(C_R)(P_R) - \frac{F_R}{V_R}(G_R)$$

$$\frac{dP_R}{dt} = \frac{F_P}{V_R}(P_L) - \frac{F_R}{V_R}(P_R) + k_2(B_R)(C_R) - 0.5k_3(C_R)(P_R)$$

$$F_R = F_A + F_B + F_L$$

$$k_1 = 5.9755 \cdot 10^9 \cdot e^{-\frac{12000}{T_r+459.67}}$$

$$k_2 = 2.5962 \cdot 10^{12} \cdot e^{-\frac{15000}{T_r+459.67}}$$

$$k_3 = 9.6823 \cdot 10^{15} \cdot e^{-\frac{20000}{T_r+459.67}}$$

EQUAÇÃO DE BALANÇO DE ENERGIA

$$\frac{dT_R}{dt} = \frac{1}{V_R \rho_R C_{PR}} \left\{ 2k_1(A_R)(B_R)H_1V_R + 3k_2(B_R)(C_R)H_2V_R + 1.5k_3(C_R)(P_R)H_3V_R - h_w A_w (T_R - T_W) + h_s A_s (T_s - T_R) - F_L C_{PL} (T_R - T_L) - F_A C_{PA} (T_R - T_A) - F_B C_{PB} (T_R - T_B) \right\}$$

, onde $F_A, F_B, \dots, F_P, F_R$ e F_L são respectivamente as vazões das substâncias A, B, \dots, P , e da mistura na saída do reator, e no refluxo; A, B, C, E, G, P com termos subscritos são as concentrações de cada substância, sendo que os subscritos R e L correspondem ao local da reação considerado, qual seja a saída do reator, ou o refluxo, respectivamente; V_R é o volume do reator, ρ_R é a densidade relativa da mistura na saída do reator, H_1, H_2 e H_3 corresponde ao calor de cada reação; h_s e h_w são os coeficientes de transferência de calor das serpentinas de vapor e

de água fria; A_s e A_w são as áreas das superfícies de contato das serpentinas; e C_{P_R} , C_{P_L} , C_{P_A} e C_{P_B} são as capacidades caloríficas das vazões no reator, no refluxo, e na alimentação de A e B . Os valores dos parâmetros podem ser encontrados em (WILLIAMS; OTTO, 1960).

APÊNDICE B – AJUSTE DE PARÂMETROS DO GPC

Simulação do processo Otto

```

HzPred=10;           % Horizonte de Predição
HzCtrl=3;           % Horizonte de Controle
Niter = 300;        % Número de iterações
lambdaG = 0.5;      % Peso de ponderação  $\lambda$ 
DeltaTrMax=25;      % Variação máxima da ação de controle  $T_R$ 
DeltaFlMax=10000;   % Variação máxima da ação de controle  $F_L$ 

```

Simulação do Reator Isotérmico

```

HzPred=6;           % Horizonte de Predição
HzCtrl=6;           % Horizonte de Controle
Niter = 200;        % Número de iterações
lambdaG = 1;        % Peso de ponderação  $\lambda$ 
DeltaP0inMax=3;     % Variação máxima da ação de controle  $P_{0in}$ 
DeltaBinMax=2;      % Variação máxima da ação de controle  $B_{in}$ 
P0inMax=10;         % Limite superior para ação de controle  $P_{0in}$ 
PBinMax=10;         % Limite superior para ação de controle  $B_{in}$ 
P0inMin=0;          % Limite inferior para ação de controle  $P_{0in}$ 
PBinMin=0;          % Limite inferior para ação de controle  $B_{in}$ 

```