



UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA QUÍMICA

**ROMERO FLORENTINO DE CARVALHO**

**PROJETO SIMULTÂNEO DE PROCESSO E SEU SISTEMA DE CONTROLE  
USANDO ESTRATÉGIAS DE CONTROLE AVANÇADO**

CAMPINAS

2021

**Romero Florentino de Carvalho**

**PROJETO SIMULTÂNEO DE PROCESSO E SEU SISTEMA DE CONTROLE  
USANDO ESTRATÉGIAS DE CONTROLE AVANÇADO**

Tese de Doutorado apresentada à Faculdade de Engenharia Química da Universidade Estadual de Campinas, como parte das exigências para obtenção do Título de Doutor em Engenharia Química.

Orientadora: Profa. Dra. Luz Adriana Alvarez Toro.

Este exemplar corresponde à versão final da dissertação defendida pelo aluno Romero Florentino de Carvalho, e orientada pela Profa. Dra. Luz Adriana Alvarez Toro.

CAMPINAS

2021

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Área de Engenharia e Arquitetura  
Rose Meire da Silva - CRB 8/5974

C253p Carvalho, Romero Florentino de, 1992-  
Projeto simultâneo de processo e seu sistema de controle usando estratégias de controle avançado / Romero Florentino de Carvalho. – Campinas, SP : [s.n.], 2021.

Orientador: Luz Adriana Alvarez Toro.  
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Controle Preditivo. 2. Otimização de processo. 3. Otimização. 4. Controle de processos químicos. 5. Processos químicos. I. Alvarez Toro, Luz Adriana, 1982-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Simultaneous process design and control using advanced control strategies

**Palavras-chave em inglês:**

Predictive control

Process optimization

Multiobjective optimization problem

Optimization

Chemical process control

Chemical process

**Área de concentração:** Engenharia Química

**Titulação:** Doutor em Engenharia Química

**Banca examinadora:**

Luz Adriana Alvarez Toro [Orientador]

Flavio Vasconcelos da Silva

Reginaldo Guirardelo

Márcio André Fernandes Martins

Bruno Faccini Santoro

**Data de defesa:** 19-11-2021

**Programa de Pós-Graduação:** Engenharia Química

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0001-8805-107X>

- Currículo Lattes do autor: <http://lattes.cnpq.br/8949967345647610>

Folha de Aprovação da Defesa de Tese de Doutorado defendida por **ROMERO FLORENTINO DE CARVALHO** e aprovada em 19 de novembro de 2021 pela Comissão Examinadora constituída pelos doutores:

Profa. Dra. Luz Adriana Alvarez Toro – Presidente e Orientadora

FEQ/UNICAMP

Videoconferência

Prof. Dr. Flavio Vasconcelos da Silva

FEQ/UNICAMP

Prof. Dr. Reginaldo Guirardelo

FEQ/UNICAMP

Videoconferência

Dr. Márcio André Fernandes Martins

Escola Politécnica da UFBA

Videoconferência

Dr. Bruno Faccini Santoro

Universidade Federal de São Paulo - Campus Diadema

Videoconferência

\*A Ata da defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

## **AGRADECIMENTO**

“Que darei ao Senhor por todos os seus benefícios para comigo?” Sl. 116:12

O motivo maior da minha gratidão vai ao Deus Todo-Poderoso, Criador do céu e da terra. Ao Senhor dos Senhores e Rei dos Reis seja o louvor e a glória pelos séculos dos séculos (Gl. 1:5). Ao Pai de amor, por sua imensa bondade, que enviou o seu Filho amado, Jesus Cristo, e a Ele por sua vida e sacrifício, que traz vida, sentido e razão para todo trabalho e ao Espírito Santo, pela iluminação, por trazer a vida de Cristo e orientar os meus passos durante toda a jornada do conhecimento, para que tudo pudesse ser por meio dEle, por Ele e para Ele.

Quero externar também minha gratidão aos meus pais, Miguel e Neize, por todo amor, apoio e por sempre acreditarem que este dia seria possível. Com toda a certeza do mundo essa conquista também é uma conquista deles.

À minha irmã Lorena, que sempre esteve perto, mesmo que distante, por todos os momentos felizes e por todo carinho demonstrado.

À Profa. Luz, por todo apoio, respeito, orientação e conversas nesta longa jornada. Muito obrigado por todo conhecimento e experiência.

Aos amigos da Faculdade de Engenharia Química, não poderia deixar de citar o Fernando Marques, o Rodrigo, João, Fernando Cassoli, Raissa, Flávio, André, Lucas e tantos outros que fizeram os meus dias mais felizes. Aos amigos e irmãos que a IPBG me deu, em especial o pastor Daniel e sua família, ao pastor Jônatas e sua família, ao Caio, ao Leonardo, ao Igor, ao Samuel, ao Nathan, meu muito obrigado pela parceria na caminhada.

Aos meus amigos de longa data Samyr, Israel e Victor, não poderia deixar de expressar minha gratidão por sempre estarem comigo. Estavam presentes no início da faculdade e estão hoje também, no término do doutorado.

Agradeço à toda comunidade da Faculdade de Engenharia Química, aos professores, alunos e demais colaboradores, pelo suporte durante esses 4 anos.

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) bolsa processo nº 155746/2017-0.

## RESUMO

Os projetos de processos e do sistema de controle são frequentemente considerados como problemas independentes, no qual, o objetivo econômico e de controle são realizados em esferas de tempo diferentes e de modo sequencial. Contudo, essa abordagem pode apresentar problemas como restrições incompatíveis e pontos operacionais inviáveis. A agregação de ambos os objetivos em uma estrutura de otimização integrada surge como uma alternativa na busca de solucionar tais limitações. Através dessa abordagem é possível fornecer um projeto de processos e do sistema de controle com benefícios econômicos e melhorias no comportamento dinâmico. A metodologia apresentada neste trabalho trata o problema de projeto de processos e do sistema de controle em uma sequência de problemas de otimização. A sua formulação baseia-se nas mudanças das condições de mercado causadas pela diferença nos preços de matérias-primas e dos produtos. Os seus estágios iniciais consistem, primeiramente, nos cálculos de projetos utópicos, realizados pela solução isolada de cada objetivo de otimização. Na última etapa, uma estrutura integrada trabalha para alcançar simultaneamente esses valores por meio de duas estratégias de otimização: alcance de metas e cálculo do custo quadrático. A metodologia foi aplicada no reator de Williams-Otto em virtude da complexidade dinâmica do sistema. Um controlador preditivo de horizonte infinito (IHMPC) e uma estrutura de integração entre este controlador e a camada de otimização em tempo real (RTO) foram usados como estratégias de controle. Os resultados apresentam que a metodologia proposta foi capaz de melhorar aspectos dinâmicos do controlador e aspectos econômicos da operação da planta mesmo na presença de alterações impostas pelo mercado aos preços dos componentes de reação, perturbações programadas, aleatórias e não medidas pelo processo.

Palavras-chave: Controle preditivo, Otimização de Processo, Problema de Otimização Multiobjetivo, Otimização, Controle de Processos Químicos, Processos Químicos.

## ABSTRACT

Process design and control are often regarded as independent issues. The economic objective and control problem are carried out in different time stages and in a sequential way. However, this approach can present problems such as constraints violation and unfeasible operational points. The aggregation of both objectives in an integrated optimization framework appears as an alternative in the search to solve such limitations. Through this methodology, it is possible to provide a process and control design with economic benefits and improvements in dynamic behavior. The methodology presented in this work deals with the process and control design problem in a sequence of optimization problems. Its formulation is based on changes in market conditions caused by differences in the prices of raw materials and products. Its initial stages consist, firstly, in the calculations of utopian projects, carried out by the isolated solution of each optimization objective. In the last step, an integrated structure works to achieve the utopian values simultaneously through two optimization strategies: attainment goals and quadratic cost. The proposed solution is applied in the Williams-Otto reactor due to the dynamic complexity of the system. An Infinite Horizon Predictive Controller (IHMPC) and an integration structure between this controller and the Real-Time Optimization (RTO) layer were used as control strategies. Results show that the proposed methodology was able to improve the dynamics aspects of the controller and economic aspects of the process operation even in the presence of changes imposed by the prices of reaction components, programmed, random, and non-measured disturbances by the process.

Keywords: Predictive control, Process Optimization, Multiobjective Optimization Problem, Optimization, Chemical Process Control, Chemical Process.

## LISTA DE FIGURAS

Figura 1 - Classificação dos métodos SPDC. Fonte: Adaptado de Sharifzadeh (2013).....	34
Figura 2 - Estratégia de implementação do IHMPC Adaptativo. Fonte: Adaptado de Camacho; Bordons, 2007.....	70
Figura 3 - Estrutura hierárquica de controle conforme a escala de tempo. Fonte: Skogestad (2000), modificado pelo autor.....	71
Figura 4 - Interação RTO e MPC Adaptativo. Adaptado de Alvarez e Odloak (2012).....	73
Figura 5 - Metodologia SPDC proposta.....	77
Figura 6 - Trajetória de referência: Resposta de primeira ordem entre dois setpoints.....	79
Figura 7 - Reator de Williams-Otto. Adaptado de Cubillos; Acuña; Lima (2007). .....	85
Figura 8 - Comportamento dinâmico das variáveis controladas (Cenário 1)....	99
Figura 9 - Comportamento dinâmico das variáveis manipuladas (Cenário 1).100	
Figura 10 - Comportamento dinâmico das variáveis controladas (Cenário 2).101	
Figura 11 - Comportamento dinâmico das variáveis manipuladas (Cenário 2). .....	102
Figura 12 - Lucro ao longo do tempo de simulação para os cenários 1 e 2... 103	
Figura 13 - Comportamento dinâmico das variáveis controladas (Cenário 1).106	
Figura 14 - Comportamento dinâmico das variáveis manipuladas (Cenário 1). .....	107
Figura 15 - Alterações nos ganhos dos modelos (Cenário 1).....	108
Figura 16 - Variações aleatórias na variável perturbação ( $F_A$ ).....	109
Figura 17 - Comportamento dinâmico das variáveis controladas (Cenário 2).109	
Figura 18 - Alterações nos ganhos dos modelos (Cenário 2).....	111
Figura 19 - Comportamento dinâmico das variáveis manipuladas (Cenário 2). .....	112
Figura 20 – Lucro obtido a cada instante de simulação. ....	114
Figura 21 - Comportamento dinâmico da variável $y_1$ para cada projeto (Cenário 1). .....	117

Figura 22 - Comportamento dinâmico da variável $y_2$ para cada projeto (Cenário 1).	118
Figura 23 - Comportamento dinâmico da variável $u_1$ para cada projeto (Cenário 1).	119
Figura 24 - Comportamento dinâmico da variável $u_2$ para cada projeto (Cenário 1).	119
Figura 25 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 1).	120
Figura 26 - Perturbações aplicadas ao sistema (Cenário 2).	121
Figura 27 - Comportamento dinâmico da variável $y_1$ para cada projeto (Cenário 2).	122
Figura 28 - Comportamento dinâmico da variável $y_2$ para cada projeto (Cenário 2).	122
Figura 29 - Comportamento dinâmico da variável $u_1$ para cada projeto (Cenário 2).	123
Figura 30 - Comportamento dinâmico da variável $u_2$ para cada projeto (Cenário 2).	124
Figura 31 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 2).	124
Figura 32 - Comportamento dinâmico da variável $y_1$ para os projetos simultâneos (Cenário 1).	129
Figura 33 - Comportamento dinâmico da variável $y_2$ para os projetos simultâneos (Cenário 1).	130
Figura 34 - Comportamento dinâmico da variável $u_1$ para os projetos simultâneos (Cenário 1).	131
Figura 35 - Comportamento dinâmico da variável $u_2$ para os projetos simultâneos (Cenário 1).	131
Figura 36 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 1).	132

Figura 37 - Comportamento dinâmico da variável $y_1$ para os projetos simultâneos (Cenário 2). .....	134
Figura 38 - Comportamento dinâmico da variável $y_2$ para os projetos simultâneos (Cenário 2). .....	134
Figura 39 - Comportamento dinâmico da variável $u_1$ para os projetos simultâneos (Cenário 2). .....	135
Figura 40 - Comportamento dinâmico da variável $u_2$ para os projetos simultâneos (Cenário 2). .....	136
Figura 41 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 2). .....	137

## LISTA DE TABELAS

Tabela 1 - Configurações e algoritmos de otimização usados no trabalho. ....	83
Tabela 2 - Preços dos compostos reacionais para as condições 1 e 2.....	88
Tabela 3 - Preços dos compostos reacionais para as condições 3 e 4.....	92
Tabela 4 - Restrições e resultados do Problema 1 para cada condição de mercado.....	95
Tabela 5 - Restrições para as variáveis de otimização dos problemas 2 e 3... ..	95
Tabela 6 - Solução ótima do Problema 2. ....	96
Tabela 7 - Solução ótima do Problema 3. ....	97
Tabela 8 - Valores dos índices econômico e dinâmico. ....	102
Tabela 9 - Resultados do projeto simultâneo do processo e seu sistema de controle usando um controlador IHMPC adaptativo.....	105
Tabela 10 - Índices econômicos e dinâmicos para ambos cenários. ....	113
Tabela 11 - Retorno esperado e condições operacionais ótimas.....	116
Tabela 12 - Parâmetros de sintonia da estrutura integrada MPC e RTO.....	116
Tabela 13 - Alterações de mercado propostas no Cenário 1. ....	117
Tabela 14 - Somatório do lucro ao longo do tempo de simulação (Cenário 1). .....	121
Tabela 15 - Somatório do lucro ao longo do tempo de simulação (Cenário 2). .....	125
Tabela 16 - Resultados do projeto simultâneo do processo e seu sistema de controle usando a estrutura integrada de IHMPC e RTO com a extensão adaptativa online. ....	127
Tabela 17 - Resultados do projeto simultâneo do processo e seu sistema de controle usando a estrutura integrada de IHMPC e RTO com a extensão adaptativa de combinação linear.....	128
Tabela 18 - Somatório do lucro ao longo do tempo de simulação (Cenário 1). .....	133
Tabela 19 - Somatório do lucro ao longo do tempo de simulação (Cenário 2). .....	136

## LISTA DE ABREVIATURAS E SIGLAS

Adp	Adaptativo
AM	Alcance de Metas
CQ	Custo Quadrático
CSTR	Reator contínuo de mistura perfeita ( <i>Continuous stirred tank reactor</i> )
IHMPC	Controlador preditivo baseado em modelo com horizonte infinito ( <i>Infinite Horizon Model Predictive Control</i> )
Lin	Linearizado por identificação
MATLAB	<i>Matrix Laboratory</i>
MIDO	Otimização dinâmica inteira mista ( <i>Mixed Integer Dynamic Optimization</i> )
MIMO	Múltiplas entradas e múltiplas saídas ( <i>Multiple Input Multiple Output</i> )
MINLP	Programação não linear inteira mista ( <i>Mixed Integer Nonlinear Programming</i> )
MPC	Controlador preditivo baseado em modelo ( <i>Model Predictive Control</i> )
NLP	Programação não linear ( <i>Nonlinear Programming</i> )
NMPC	Controlador preditivo baseado em modelo não linear ( <i>Nonlinear Model Predictive Control</i> )
OPOM	Modelo de predição orientado à saída ( <i>Output Predictive Oriented Model</i> )
PAD	Padrão
PI	Controlador Proporcional Integral
PID	Controlador Proporcional Integral Derivativo
RTO	Otimização em tempo real ( <i>Real-Time Optimization</i> )

SEQ	Sequencial
SISO	Única entrada e única saída ( <i>Single Input Single Output</i> )
SPDC	Projeto simultâneo de processos e do sistema de controle ( <i>Simultaneous Process Design and Control</i> )

## LISTA DE SÍMBOLOS

### Símbolos romanos

$\mathbf{0}_{nx}$	Matriz de zeros com dimensão $nx$
$\mathbf{A}$	Matriz de estados do modelo em espaço de estados no tempo discreto.
$a$	Derivada parcial da função de estado em relação aos estados.
$a_{i,j,l}$	Coeficientes do denominador da função de transferência $G_{i,j}(s)$ .
$\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{E}, \mathbf{G}, \mathbf{P}$	Componentes racionais do reator de Williams-Otto.
$\mathbf{B}$	Matriz de entradas do modelo em espaço de estados no tempo discreto.
$b$	Derivada parcial da função de estado em relação às entradas.
$b_{i,j,l}$	Coeficientes do numerador da função de transferência $G_{i,j}(s)$ .
$\mathbf{C}$	Matriz de saídas do modelo em espaço de estados no tempo discreto.
$\mathbf{c}$	Gradiente da função objetivo do problema de programação quadrática do IHMPC.
$c$	Derivada parcial da função de saída em relação aos estados.
$\mathbf{c}_f$	Matriz auxiliar da função objetivo do problema de otimização quadrática do IHMPC.
$\mathbf{C}_u$	Vetor com pesos do desvio dos <i>targets</i> das entradas na função objetivo da camada TC.
$\mathbf{C}_y$	Vetor com pesos do desvio dos <i>targets</i> das saídas na função objetivo da camada TC.

$C_\varepsilon$	Vetor com pesos das variáveis de folga na função objetivo da camada TC.
$C_2$	Preço relacionado ao custo de utilidade da operação do reator.
$\mathbf{d}(k)$	Perturbações no sistema.
$d_{na}^i$	Coefficientes de expansão parcial da função de transferência.
$\mathbf{D}^0$	Matriz com os ganhos estáticos definidos pelo modelo OPOM para os estados $\mathbf{x}^s$ .
$\mathbf{D}^d$	Matriz definida pelo modelo OPOM para os estados $\mathbf{x}^d$ .
$\mathbf{D}_m^0$	Matriz de ganho estático do modelo nominal.
$\tilde{\mathbf{D}}^0$	Matriz auxiliar da restrição do problema de otimização do IHMPC.
$\mathbf{e}^s(k)$	Erro entre o valor de $\mathbf{x}^s(k)$ e $\mathbf{y}^{sp}(k)$ .
$\mathbf{F}$	Matriz do modelo OPOM relacionada com os polos da função de transferência.
$\mathbf{f}$	Vetor com as equações diferenciais que representam o modelo do sistema.
$f$	Função não linear dinâmica que descreve o estado do sistema.
$\hat{J}_{RTO}$	Função objetivo econômica para otimização em tempo real.
$F_A$	Vazão de entrada do componente $A$ .
$F_B$	Vazão de entrada do componente $B$ .
$F_E$	Vazão de saída do componente $E$ .
$F_P$	Vazão de saída do componente $P$ .
$F_R$	Vazão de saída do reator.
$\mathbf{G}(s)$	Matriz de funções de transferência do sistema.

$\mathbf{g}$	Vetor com as restrições de igualdade do sistema.
$G_{i,j}(s)$	Função de transferência da saída $y_i$ e entrada $u_j$ .
$\mathbf{H}$	Matriz Hessiana do problema de otimização quadrática do IHMPC.
$\mathbf{h}$	Vetor com as restrições de desigualdade do sistema.
$h$	Função não linear que descreve a saída do processo.
$\tilde{\mathbf{I}}$	Matriz construída a partir de $\mathbf{I}_{nu}$ e que aparece na restrição de entrada da camada TC.
$\mathbf{I}_{nu}$	Matriz identidade com dimensão $nu$ .
$\mathbf{I}_{ny}$	Matriz identidade com dimensão $ny$ .
$\mathbf{J}$	Matriz definida pelo modelo OPOM.
$J(k)$	Função objetivo dos problemas de otimização da estrutura integrada MPC e RTO.
$\mathbf{K}_F$	Ganho de Kalman.
$\mathbf{K}_{MPC}$	Ganho do controlador MPC obtido pela solução do problema de otimização sem restrição.
$k_1, k_2, k_3$	Constantes de reação, definidas pela equação de Arrhenius.
$m$	Horizonte de controle.
$M_B, M_C,$	
$M_E, M_G,$	Massas moleculares das espécies $B, C, E, G$ e $P$ .
$M_P$	
$\mathbf{N}$	Matriz auxiliar definida pelo modelo OPOM.
$na$	Número de polos da função de transferência $G_{i,j}(s)$ .
$nb$	Número de zeros da função de transferência $G_{i,j}(s)$ .

$ny$	Número de variáveis de saídas.
$nu$	Número de variáveis de entradas.
$nu_t$	Número de variáveis de entradas otimizadas.
$P_A, P_B,$ $P_E, P_P$	Preço dos elementos reacionais $A, B, C, E$ e $P$ (\$/kg).
$\mathbf{Q}$	Matriz diagonal positiva com os pesos relacionados aos erros das saídas controladas em relação aos valores desejados.
$\bar{\mathbf{Q}}$	Matriz com pesos terminais do IHMPC.
$\mathbf{Q}_1$	Matriz auxiliar do problema de otimização do IHMPC.
$\mathbf{Q}_2$	Matriz auxiliar do problema de otimização do IHMPC.
$\mathbf{Q}_u$	Matriz com os pesos dos <i>targets</i> das entradas na função objetivo da camada MPC.
$\mathbf{Q}_y$	Matriz com os pesos dos <i>targets</i> das saídas na função objetivo da camada do MPC.
$\mathbf{R}$	Matriz diagonal positiva com os pesos relacionados aos esforços realizados pelo controlador nas variáveis manipuladas.
$r$	Polos da função de transferência do sistema.
$\mathbf{R}_1$	Matriz auxiliar do problema de otimização do IHMPC.
$\mathbf{S}$	Matriz definida positiva para minimizar ou zerar as folgas do IHMPC.
$S_{i,j}(k)$	Resposta ao degrau de $G_{i,j}(s)$ no instante $k$ para o período de amostragem $\Delta t$ .
$\mathbf{S}_y$	Matriz com os pesos das folgas das saídas na função objetivo da camada MPC.
$T_R$	Temperatura do reator.

$\mathbf{u}$	Vetor de variáveis de entrada.
$\mathbf{u}(k-1)$	Vetor das entradas no instante de tempo anterior.
$\mathbf{u}_{des}(k)$	Vetor com os <i>targets</i> das entradas calculado pela camada TC.
$\mathbf{u}_{RTO}$	Vetor com os <i>targets</i> das entradas calculado pela camada RTO.
$\mathbf{v}$	Vetor com os parâmetros do sistema de controle.
$W$	Massa reacional.
$\mathbf{x}$	Vetor dos estados do processo.
$\dot{\mathbf{x}}$	Vetor com as derivadas dos estados em relação ao tempo.
$\mathbf{x}^s$	Vetor de estados integradores gerados pela forma incremental do modelo.
$\mathbf{x}^d$	Vetor de estados ou modos estáveis.
$x', y', u'$	Variáveis desvio.
$X_A, X_B,$	
$X_C, X_E,$	Fração dos produtos na corrente de saída $F_R$ .
$X_G, X_P$	
$\mathbf{y}$	Vetor das variáveis de saída.
$\mathbf{y}(\infty k)$	Vetor com as saídas previstas no tempo infinito.
$y'(s), u'(s)$	Variáveis no domínio de Laplace.
$\mathbf{y}_{des}(k)$	Vetor com os <i>targets</i> das saídas calculado pela camada TC.
$\mathbf{y}_{medido}(k)$	Saída medida do processo.
$\mathbf{y}_p(k)$	Saída do processo.
$y_{ref}^i(k)$	Referência a ser seguida pelo objetivo dinâmico no instante de tempo atual.

$\mathbf{y}_{RTO}$  Vetor com os *targets* das saídas calculado pela camada RTO.

$\mathbf{y}^{sp}$  Vetor com os valores desejados das variáveis controladas.

### Símbolos gregos

$\gamma$  Variável de folga para minimizar simultaneamente um conjunto de objetivos.

$\Delta t$  Período de amostragem.

$\Delta \mathbf{u}$  Vetor de ações de controle do tempo  $k$  até  $m-1$ .

$\Delta \mathbf{u}(k | k)$  Elemento da sequência ótima aplicado ao processo.

$\Delta \mathbf{u}(k + j | k)$  Sequência ótima de ações de controle encontrada pelo otimizador.

$\delta(k)$  Vetor de variáveis de folga do IHMPC.

$\delta_y(k)$  Vetor de variáveis de folga da saída.

$\varepsilon(k)$  Vetor de variável de folga da camada TC.

$\theta_1$  Tempo em que ocorre a alteração dos preços no problema dinâmico da metodologia SPDC.

$\sigma_1, \sigma_2, \sigma_3$  Taxas de reações.

$\tau_i$  Constante de tempo da trajetória ótima do objetivo dinâmico do problema SPDC.

$v_i(k)$  Pesos das ações de controle correspondente a cada modelo  $i$  no instante de tempo  $k$ .

$\Phi$  Matriz auxiliar com número 1 definida para o modelo OPOM.

$\phi_{dyn}$  Objetivo dinâmico do problema SPDC.

$\phi_{eco}$  Objetivo econômico do problema SPDC.

$\phi_{dyn}^{Ut}$  Objetivo dinâmico utópico.

$\phi_{eco}^{Ut}$	Objetivo econômico utópico.
$\phi_{SPDC}$	Função objetivo do problema SPDC.
$\Psi$	Matriz definida para o modelo OPOM.
$\psi$	Matriz diagonal positiva definida com os valores de pesos de rastreamento da trajetória ideal.
$\Psi_D$	Peso atribuído ao objetivo dinâmico na otimização por alcance de metas.
$\Psi_E$	Peso atribuído ao objetivo econômico na otimização por alcance de metas.
$\Psi_1$	Matriz auxiliar do problema de otimização do IHMPC.
$\Omega_D$	Peso atribuído ao objetivo dinâmico na otimização por custo quadrático.
$\Omega_E$	Peso atribuído ao objetivo econômico na otimização por custo quadrático.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>23</b>
1.1	Justificativa.....	28
1.2	Objetivos .....	29
1.3	Organização do texto .....	30
1.4	Lista de publicações.....	31
1.4.1	Publicações em revistas .....	31
1.4.2	Publicações em congressos .....	31
<b>2</b>	<b>PROJETO INTEGRADO DE PROCESSOS E DE SEU SISTEMA DE CONTROLE .....</b>	<b>33</b>
2.1	Classificação das metodologias de problema simultâneo do projeto de processo e seu sistema de controle.....	33
2.2	Formulação Geral do Projeto Simultâneo de Processos e de Sistema de Controle .....	35
2.3	Métodos baseados em índices de controlabilidade e propriedades relacionadas.....	38
2.3.1	Métodos baseados nos índices de controlabilidade .....	38
2.3.2	Métodos baseados na dinâmica do modelo não linear .....	40
2.3.3	Métodos baseados na análise de robustez .....	42
2.3.4	Métodos baseados em análise probabilística .....	43
2.4	Métodos baseados na estratégia de controle.....	44
2.4.1	Métodos de controle clássico.....	44
2.4.2	Métodos de controle avançado.....	46
2.5	Métodos baseados na formulação do problema de otimização .....	48
2.5.1	Formulações do tipo multiobjetivo .....	49
2.5.2	Formulação com subproblemas de otimização .....	51
2.6	Desafios atuais.....	52
<b>3</b>	<b>CONTROLADOR PREDITIVO BASEADO EM MODELO (MPC) .....</b>	<b>55</b>
3.1	MPC Clássico.....	55
3.2	MPC de horizonte infinito (IH MPC) .....	59
3.3	Controlador IH MPC com variáveis de folga .....	65
3.4	Estratégia de adaptação .....	68
3.5	Integração estável MPC e RTO .....	71
3.5.1	Integração estável de MPC e RTO em três camadas.....	73
3.6	Comentários finais.....	75

<b>4</b>	<b>METODOLOGIA</b>	<b>76</b>
4.1	Formulação geral do problema SPDC	76
4.2	Estratégias de solução do problema de otimização	80
4.2.1	Alcance de metas	80
4.2.2	Custo quadrático	81
4.3	Projeto simultâneo usando IHMPC linear	81
4.4	Projeto simultâneo usando IHMPC adaptativo	83
4.5	Projeto simultâneo usando a estrutura MPC-RTO em três camadas	84
<b>5</b>	<b>Estudo de caso</b>	<b>85</b>
5.1	Estudo de caso: Reator Williams-Otto	85
5.2	Objetivo econômico: Problema 1	87
5.3	Objetivo dinâmico e simultâneo (problemas 2 e 3)	89
5.3.1	Identificação do modelo para o IHMPC	89
5.3.2	IHMPC usando um modelo linear adaptativo com atualizações em cada instante de tempo	90
5.3.3	Integração do IHMPC Adaptativo com RTO	92
<b>6</b>	<b>RESULTADOS</b>	<b>94</b>
6.1	Projeto simultâneo de processos e de seu sistema de controle usando um IHMPC nominal	94
6.2	Projeto simultâneo de processos e de seu sistema de controle usando um IHMPC adaptativo	104
6.3	Projeto simultâneo de processos e de seu sistema de controle usando um IHMPC adaptativo em uma estrutura de MPC e RTO	114
6.3.1	Análise financeira de múltiplos projetos	115
6.3.2	Projeto simultâneo de processos e do sistema de controle usando a estrutura IHMPC e RTO considerando extensões adaptativas	126
<b>7</b>	<b>CONCLUSÕES</b>	<b>138</b>
<b>8</b>	<b>REFERÊNCIAS</b>	<b>141</b>

## 1 INTRODUÇÃO

De modo geral, o projeto de processos químicos está relacionado à otimização de uma função objetivo que mensura aspectos econômicos do sistema (ASTEASUAIN *et al.*, 2006). O procedimento de otimização define a estrutura do processo, a disposição e o tamanho dos equipamentos e as condições operacionais que atendam a requisitos de segurança e especificação de produtos (KYRIAKIDES *et al.*, 2019; VEGA *et al.*, 2014b; YUAN *et al.*, 2012). O projeto ótimo é obtido a partir da solução de um problema de otimização restrito por um modelo matemático do sistema em estado estacionário, sem considerar aspectos dinâmicos que possam afetar a operação (KYRIAKIDES *et al.*, 2019). Entretanto, fatores como perturbações, incertezas nos parâmetros e variações no regime operacional podem alterar a operação do processo e resultar em mudanças em suas condições (KYRIAKIDES *et al.*, 2019).

Se, por um lado, há relativos ganhos do ponto de vista econômico, por outro, a prática industrial demonstra que os aspectos de controle tornam-se mais relevantes à medida que a complexidade do sistema aumenta (KYRIAKIDES *et al.*, 2019; YUAN *et al.*, 2012). Além disso, o desempenho dinâmico do sistema também pode ser afetado pela disponibilidade de medidas precisas e pelo atraso na resposta dinâmica da medição (HUUSOM, 2015). Portanto, é essencial aplicar estratégias de controle adequadas para garantir a operação ideal e viável simultaneamente (EDGAR, 2004; PATEL; UYGUN; HUANG, 2008; SHARIFZADEH, 2013). O projeto desses sistemas, por sua vez, envolve a escolha das variáveis controladas e manipuladas, dos objetivos, do algoritmo de controle e o ajuste dos parâmetros na busca do desempenho ótimo (KYRIAKIDES *et al.*, 2019).

Tradicionalmente, o projeto de processos (busca por desempenho econômico) e do sistema de controle (busca pela operação e estrutura de controle adequadas) são tratados como dois problemas independentes e realizados de modo sequencial (ZHOU *et al.*, 2015). Seleciona-se primeiro a estrutura do processo, determinando os parâmetros e as condições operacionais ótimas baseados no estado estacionário e em objetivos econômicos, levando em conta as restrições do processo (VEGA *et al.*, 2014b). Com o projeto ideal em

estado estacionário determinado, utiliza-se o sistema de controle para garantir que o processo opere nos valores desejados, na presença de perturbações e incertezas dos parâmetros do modelo (BAHAKIM; RICARDEZ-SANDOVAL, 2014; BERNAL *et al.*, 2018; SHARIFZADEH, 2013).

Entretanto, a abordagem tradicional apresenta algumas limitações e pode revelar-se inadequada para obter plantas integradas competitivas e de baixo custo. Essas limitações estão principalmente relacionadas com a violação de restrições dinâmicas, por exemplo, pontos de operações inviáveis, desempenho insuficiente, etc. Além disso, com o uso dessa metodologia, nem sempre uma performance robusta é garantida e as decisões do projeto de processos podem influenciar o controle e a operação dinâmica do processo. Um modo prático de se adaptar a esse tipo de situação consiste em adicionar fatores de sobredimensionamento que, por um lado, corrigem certas limitações, mas, por outro, podem aumentar significativamente os custos do projeto (KYRIAKIDES *et al.*, 2019; VEGA *et al.*, 2014b; YUAN *et al.*, 2012).

Nos últimos anos, metodologias de projeto simultâneo de processos e do sistema de controle têm sido empregadas para alcançar simultaneamente as performances econômicas e dinâmicas desejadas (KYRIAKIDES *et al.*, 2019; YUAN *et al.*, 2012). Na literatura, essa abordagem é comumente tratada como projeto simultâneo do processo e do sistema de controle (SPDC, do inglês *Simultaneous Process Design and Control*). Nessa metodologia é realizada uma análise sistemática da dinâmica da planta, de modo que mesma seja inserida no projeto dos processos com o intuito de obter uma solução que representa o compromisso entre a economia ou aspectos do processo em conjunto com os aspectos do controlador (BAHAKIM; RICARDEZ-SANDOVAL, 2014; RICARDEZ-SANDOVAL; BUDMAN; DOUGLAS, 2009; VEGA *et al.*, 2014b).

As metodologias SPDC geralmente são formuladas como um problema de otimização de múltiplos objetivos no qual os dois objetivos conflitantes entre si (HUUSOM, 2015). O problema de otimização pode ser resolvido por meio de programação não linear inteira mista (MINLP, do inglês *Mixed integer nonlinear programming*), ou por otimização dinâmica inteira mista (MIDO, do inglês *Mixed integer dynamic optimization*), determinando os projetos de processo e de controle em uma única etapa (ASTEASUAIN *et al.*, 2004; SCHWEIGER;

FLOUDAS, 1998). No entanto, devido ao tamanho do problema e as múltiplas soluções apresentadas, é importante usar procedimentos de inicialização e decomposição adequados para obter uma solução eficiente para o problema (FLORES-TLACUAHUAC; GROSSMANN, 2010; SHARIFZADEH, 2013).

Um dos grandes desafios em aplicações de SPDC é representar a mudança nas variáveis de decisão na dinâmica do sistema e incluir a dinâmica em malha fechada no problema de projeto (SAKIZLIS; PERKINS; PISTIKOPOULOS, 2003a; YUAN *et al.*, 2012). A maneira mais prática de resolver um problema com dois objetivos é abordar os problemas individuais, de modo que cada um seja limitado pelo outro (SHARIFZADEH, 2013). As decisões entre a configuração do fluxograma e cada par possível de variáveis manipuladas e controladas podem causar uma ampla gama de alternativas de projeto e, portanto, criar descontinuidades no espaço de busca (FRANCISCO; VEGA; ÁLVAREZ, 2011; RAFIEI; RICARDEZ-SANDOVAL, 2020). Para reduzir a complexidade combinatória dos projetos, Yuan *et al.* (2012) propuseram uma formulação de projeto de processos e de controle separadas, tornando-a mais tratável. O problema de otimização foi formulado e resolvido por uma abordagem em 2 etapas (MALCOLM *et al.*, 2007). A primeira fase (mestre) buscou a decisão ótima de projetos, enquanto a segunda etapa buscou o desempenho dinâmico (com base nas decisões tomadas na camada mestre), as estratégias de controle e os parâmetros de ajuste do controlador. O objetivo da metodologia consistiu em decompor a otimização em uma metodologia baseada em etapas, delegando as decisões de controle a subproblemas que adaptam os movimentos de controle adequados para um determinado projeto. As decisões de controle são incorporadas em cada projeto, evitando um aumento no número de alternativas de controle (MALCOLM *et al.*, 2007; MOON; KIM; LINNINGER, 2011a, 2011b).

Os controladores preditivos baseados em modelo (MPC, do inglês *Model Predictive Control*) são uma ferramenta útil no controle de processos devido às suas características de lidar com restrições, tempo morto e sistemas de múltiplas entradas e saídas (MIMO, do inglês *Multiple Input Multiple Output*). Contudo, ainda que tenham desvantagens consideráveis, os controladores PID contribuem para uma parte significativa de problemas SPDC na literatura, devido principalmente à natureza implícita da solução online de um problema de

otimização a cada tempo de amostragem no MPC (BURNAK *et al.*, 2019; DIANGELAKIS *et al.*, 2017). Mesmo assim, os controladores MPC são incrivelmente atraentes para resolver problemas SPDC quem buscam um melhor desempenho dinâmico (RAFIEI; RICARDEZ-SANDOVAL, 2020; VEGA *et al.*, 2014b).

A maior parte das aplicações de MPC na literatura é baseada em um modelo linear na estrutura de controle. Desse modo, a definição de um modelo melhor modelo para uma determinada região operacional é crucial para a sua precisão, desempenho e estabilidade (FRANCISCO; VEGA; ÁLVAREZ, 2011; GUTIERREZ *et al.*, 2014; RAFIEI; RICARDEZ-SANDOVAL, 2020). Além disso, como a maioria dos sistemas químicos apresentam comportamento não lineares e operam em diferentes condições operacionais, há um certo erro entre a saída da planta e o controlador, que em geral são compensados pela malha fechada, mas por outro, pode tornar a aplicabilidade de um único modelo linear limitada às pequenas regiões em torno do qual o mesmo foi obtido (CHAWANKUL *et al.*, 2007; RAFIEI; RICARDEZ-SANDOVAL, 2020).

Soluções para este problema em metodologias SPDC incluem: (1) a abordagem de *back-off*, (2) o projeto com um controlador robusto e (3) o uso de um MPC multiparamétrico (DIANGELAKIS *et al.*, 2017). O principal desafio da primeira metodologia é quantificar a magnitude do recuo necessário para oferecer condições de processo transitórias e viáveis na presença de perturbações e incertezas nos parâmetros do modelo (DIANGELAKIS *et al.*, 2017; MEHTA; RICARDEZ-SANDOVAL, 2016; RAFIEI-SHISHAVAN; MEHTA; RICARDEZ-SANDOVAL, 2017). A abordagem que utiliza um controlador robusto é uma alternativa em que vários modelos, obtidos em diferentes condições de operação, são utilizados. Desse modo, a saída predita é obtida por meio de uma seleção entre a resposta desses controladores. Contudo, ao prever uma grande região de operação, esta abordagem requer muitos modelos e pode tornar-se mais custosa computacionalmente (ADETOLA; GUAY, 2009; DE OLIVEIRA; DE CARVALHO; ALVAREZ, 2019; FRANCISCO; VEGA; ÁLVAREZ, 2011; SHI; YUAN; LIU, 2018). Evitando uma solução *online*, as abordagens multiparamétricas propõem uma otimização *off-line* que pode incorporar ações de controle explícitas na otimização dinâmica, eliminando essas dificuldades e

incluindo todos os aspectos do MPC sem simplificações (DIANGELAKIS *et al.*, 2017). Uma outra solução proposta consiste no uso de um controlador preditivo não linear (NMPC, do inglês *Nonlinear Model Predictive Control*). Contudo, essa abordagem ainda é um desafio em aberto, devido a não convexidade do problema de otimização não linear adicionada ao problema integrado, que pode aumentar sua complexidade e custo computacional (KYRIAKIDES *et al.*, 2019).

Neste trabalho, o foco consistiu em fornecer uma estratégia de controle eficaz para sistemas desafiadores do ponto de vista dinâmico. A escolha de definir uma estratégia e estrutura de controle previamente visou eliminar as decisões de seleção de estrutura e reduzir a complexidade do problema de otimização, o que torna o problema ainda mais tratável do ponto de vista computacional. Um controlador MPC de horizonte infinito (IHMPC, do inglês *Infinite Horizon Model Predictive Control*), com estabilidade nominal, independentemente do valor dos parâmetros de ajuste do modelo foi utilizado buscando atender os desafios atuais em trabalhos de SPDC (ODLOAK, 2004; RAFIEI; RICARDEZ-SANDOVAL, 2020).

Uma estratégia adaptativa foi empregada como alternativa ao MPC linear na metodologia SPDC com um modelo obtido em torno de um único ponto de operação. Buscou-se usar uma estratégia em que os modelos foram atualizados a cada instante de tempo, buscando evitar uma combinação não adequada entre o modelo da planta e o modelo do MPC quando ocorrem mudanças nas condições do processo. O modelo do controlador foi linearizado por expansão de série de Taylor, a partir do modelo não linear do processo, mantendo a convexidade do problema e fornecendo uma solução com menor complexidade computacional do que um controlador não linear, embora neste caso a propriedade de estabilidade em condição nominal seja perdida. A estratégia adaptativa, por fim, foi avaliada em uma estrutura de controle em que o controlador IHMPC foi integrado com a camada de otimização em tempo real (RTO, do inglês *Real-Time Optimization*). Com o intuito de avaliar o desempenho econômico e o dinâmico por meio de efeito das perturbações externas e as incertezas nos parâmetros do modelo de predição, a estratégia adaptativa foi comparada com uma estratégia robusta e uma estratégia de múltiplos modelos,

definidos em torno das condições operacionais obtidas para os cenários de mercado escolhidos.

A metodologia SPDC apresentada baseia-se no rastreamento dos valores utópicos dos objetivos econômicos e dinâmicos, primeiramente avaliados de maneira separada. O objetivo econômico está relacionado ao retorno percentual esperado (%) para um ano de operação da planta. Por sua vez, o objetivo dinâmico foi avaliado através da análise da flexibilidade do processo, considerando que o comportamento da variável controlada respeita uma equação de primeira ordem devido a uma mudança degrau nos seus valores desejados, que ocorrem por causa das variações no preço de mercado de produtos químicos do reator de Williams-Otto. O problema de múltiplos objetivos foi definido como uma função de um só objetivo dada por uma combinação linear que rastreia os valores utópicos calculados nos primeiros passos.

### **1.1 Justificativa**

É de consenso a necessidade de desenvolvimento de metodologias que integram projeto de processos e de seu sistema de controle para processos químicos, principalmente no que diz respeito a processos industriais mais complexos (SHARIFZADEH, 2013). Ao se referir a essa metodologia, o termo “projeto de processos” está relacionado às decisões do sistema que determinam a topologia do fluxograma, os parâmetros e as condições operacionais com base no modelo do processo em estado estacionário e uma função de custo econômico (VEGA *et al.*, 2014b; YUAN *et al.*, 2012). A expressão “projeto de controle” relaciona-se com a busca de definir o projeto do sistema de controle utilizado no processo, que resulta de uma análise do desempenho dinâmico do sistema em malha aberta ou malha fechada. Como não há garantia de que as condições operacionais ótimas projetadas satisfaçam, de maneira ótima, o desempenho dinâmico da planta na presença de perturbações externas ou incertezas nos parâmetros do modelo, torna-se então necessário avaliar ambos projetos de forma conjunta (YUAN *et al.*, 2012).

Uma quantidade significativa de métodos integrados do projeto de processos e de seu sistema de controle foi desenvolvida e apresentada nos últimos anos, com o foco da pesquisa variando de acordo com os elementos individuais de cada problema. Em destaque estão os diferentes métodos de projeto de estrutura de controle, que variam de acordo com o tipo de controlador utilizado, desde o controle de auto-otimizante até sistemas avançados de controle, como o controle MPC. A literatura apresenta uma série de estudos de caso, incluindo processos com alto grau de complexidade (SHARIFZADEH, 2013). Nas últimas décadas, as estratégias de controle avançadas apresentam-se como uma alternativa para a melhoria do desempenho do sistema projetado. Essa característica está atrelada ao fato das ações ótimas de controle implementadas na planta serem obtidas a partir de um problema de otimização com restrições (RAFIEI; RICARDEZ-SANDOVAL, 2020; VEGA *et al.*, 2014b).

Diante desse cenário, o presente trabalho busca a apresentação de uma metodologia de projeto de processos integrado ao sistema de controle. Com o objetivo de atender os desafios atuais da área, a metodologia considera estratégias de controle avançado e sua integração com a camada de otimização em tempo real em três camadas. Além disso, a proposta realiza uma avaliação de aspectos de planejamento de processo ao considerar alterações nas condições de mercado do sistema pela variação de preços dos produtos e reagentes reacionais.

## **1.2 Objetivos**

Desenvolver uma metodologia SPDC que considera objetivos econômicos, dinâmicos, aspectos de planejamento e a utilização de técnicas de controle avançado.

Os objetivos específicos do problema proposto neste trabalho estão concentrados em:

- Avaliar o projeto simultâneo ótimo do sistema em uma comparação com uma estratégia sequencial de projeto de processos e do sistema de controle;
- Aplicar a metodologia em uma configuração de controlador adaptativo e avaliar as vantagens obtidas em termos de performance dinâmica e econômica pelo processo, quando este está exposto a perturbações externas e aleatórias;
- Avaliar aspectos de planejamento de processos ao alterar os preços dos reagentes e produtos reacionais;
- Analisar a resposta dinâmica e econômica de uma estratégia de controle adaptativa em que a estrutura de integração das camadas MPC e RTO em três camadas é considerada;
- Comparar o desempenho dinâmico, computacional e econômico da abordagem adaptativa com uma abordagem de múltiplos modelos em cenários de perturbações externas e incertezas.

### **1.3 Organização do texto**

Este documento é composto por sete capítulos, incluindo este, contendo a apresentação e os objetivos. Os capítulos seguintes são definidos da seguinte maneira:

O capítulo 2 apresenta o estado da arte detalhado sobre os problemas SPDC, além de uma visão geral sobre conceitos relevantes para a formulação geral do problema de otimização.

O capítulo 3 contém o equacionamento e desenvolvimento dos controladores preditivos e as diferentes estratégias de controle empregadas no desenvolvimento da metodologia simultânea.

O capítulo 4 da tese apresenta a formulação matemática da metodologia proposta de projeto de processos integrado ao projeto de controle.

O capítulo 5 apresenta os estudos de caso, suas particularidades (modelos e parâmetros de cada sistema), o detalhamento das funções de custo

operacional e capital usadas na formulação, bem como as variáveis a serem consideradas no problema de otimização.

Em seguida, o capítulo 6 apresenta a discussão para os resultados em que a metodologia é aplicada e comparada com uma abordagem sequencial e entre si para diferentes cenários de operação dos processos, apresentando os aspectos de melhora obtidos em termos de comportamento dinâmico e econômico das plantas.

O capítulo 7 é reservado para as conclusões, desafios e oportunidades futuras de pesquisa orientadas pelos resultados e estudos realizados.

### **1.4 Lista de publicações**

#### 1.4.1 Publicações em revistas

1. DE OLIVEIRA, RAISSA C.; DE CARVALHO, ROMERO F.; ALVAREZ, LUZ A. Multi-Model Adaptive Integration of Real Time Optimization and Model Predictive Control. IFAC-PAPERSONLINE, v. 52, p. 661-666, 2019.
2. CARVALHO, R. F. De; ALVAREZ, L. A. Simultaneous Process Design and Control of the Williams-Otto Reactor Using Infinite Horizon Model Predictive Control. Industrial & Engineering Chemistry Research, 2020.

#### 1.4.2 Publicações em congressos

1. CARVALHO, R. F.; ALVAREZ, LUZ A. Dynamic Simulation and financial analysis of multiple design for the Williams-Otto reactor. In: XXII Encontro Nacional de Modelagem Computacional e X Encontro de Ciência e Tecnologia de Materiais, 2019, Juiz de Fora. Anais do XXII Encontro Nacional de Modelagem Computacional e X Encontro de Ciência e Tecnologia de Materiais, 2019.

2. CARVALHO, R. F.; ALVAREZ, LUZ A. Sintonia ótima de um controlador MPC aplicado à planta de Williams-Otto. In: CONGRESSO BRASILEIRO DE INSTRUMENTAÇÃO, SISTEMAS E AUTOMAÇÃO, 2019, Campinas. Anais eletrônicos do Congresso Brasileiro de Instrumentação, Sistemas e Automação, 2019. v. 1.
3. CARVALHO, R. F.; ALVAREZ, LUZ A. Optimal MPC Tuning based on the Weighted ISE Minimization for a Reference Trajectory. In: IEEE 4th Colombian Conference on Automatic Control, 2019, Medellín. IEEE 4th Colombian Conference on Automatic Control, 2019.

## 2 PROJETO INTEGRADO DE PROCESSOS E DE SEU SISTEMA DE CONTROLE

Os processos modernos devem manter-se competitivos, com instalações integradas e operando com requisitos de segurança e ambientais cada vez mais rigorosos. Além disso, é necessário que na etapa de projeto suas restrições operacionais sejam rigorosamente respeitadas. Por outro lado, para garantir que uma planta atenda a um critério de desempenho dinâmico desejável, torna-se necessário analisar sua capacidade de controle ao considerar uma estrutura de controle apropriada, além da especificação relativa dos parâmetros de sintonia para o algoritmo de controle selecionado. Por ser um problema demasiadamente complexo, não existe uma abordagem única para a síntese de um problema de projeto de processos e seu controle integrados. De forma geral, as metodologias buscam tratar de questões relacionadas ao projeto robusto sob perturbações e incertezas, a seleção de uma estrutura e estratégia de controle apropriadas, bem como a formulação do problema de otimização e seleção de um algoritmo de solução eficiente (SHARIFZADEH, 2013; YUAN *et al.*, 2012).

### ***2.1 Classificação das metodologias de problema simultâneo do projeto de processo e seu sistema de controle***

As diferentes possibilidades de integração dos problemas de projeto de processos e do sistema de controle são evidenciadas nas revisões publicadas na literatura ao longo dos anos (SHARIFZADEH, 2013; VEGA *et al.*, 2014b; YUAN *et al.*, 2012). As revisões mais recentes sobre o estado da arte e as classificações se concentram em duas categorias: métodos baseados em alternativas de projetos e métodos baseados no problema de otimização integrado (VEGA *et al.*, 2014b).

Os primeiros métodos incluem o estudo do comportamento dinâmico do sistema desde as etapas iniciais do projeto de processos, com o objetivo de obter plantas mais fáceis de controlar. A integração é realizada usando métricas como a controlabilidade e a análise de propriedades similares aos projetos alternativos

da planta, que em geral, são obtidos por meio de avaliação econômica preliminar. O projeto final ótimo é obtido pela integração do projeto de processos com a análise dinâmica do sistema após uma comparação de diferentes níveis de controle. Os métodos da segunda classe são aqueles nos quais as medidas de desempenho dinâmico do sistema são introduzidas na etapa de projeto de processos, originando um problema de otimização que abrange objetivos distintos e produz de maneira simultânea a melhor planta que atende a requisitos econômicos e controláveis, incluindo a estrutura e sintonia dos sistemas de controle (VEGA *et al.*, 2014b; YUAN *et al.*, 2012).

Este trabalho está focado na segunda classe de métodos, ou seja, aqueles que realizam a busca do projeto de processo em conjunto com a otimização do projeto do controlador. Como dito, a integração de ambos objetivos resulta em um problema de otimização, que pode ser classificado utilizando uma classificação (Figura 1) baseada nos trabalhos de Vega *et al.* (2014), Yuan *et al.* (2012), Sharifzadeh (2013) e Aneesh *et al.* (2016).

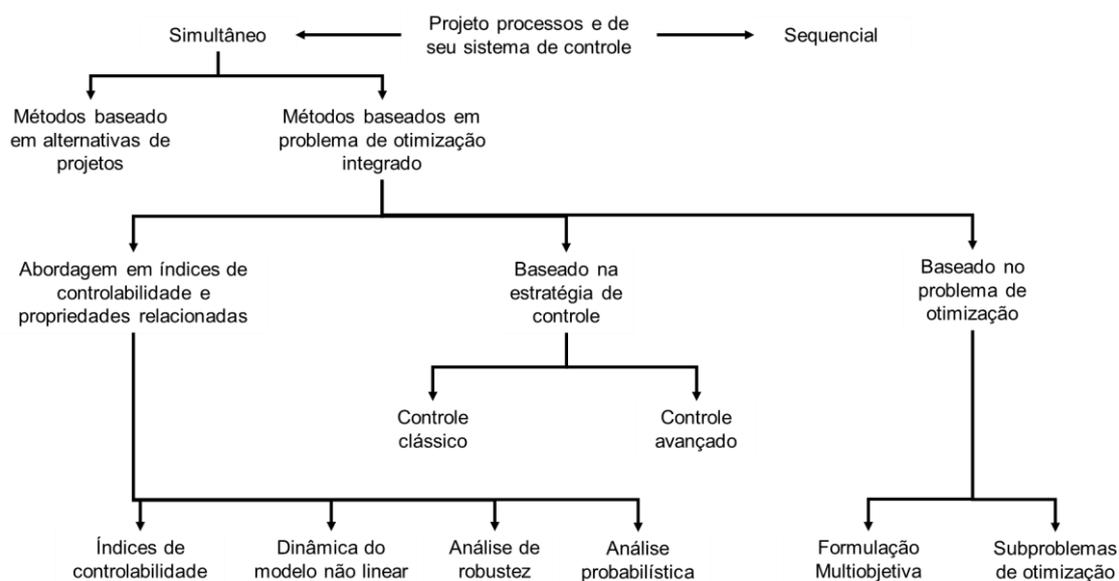


Figura 1 - Classificação dos métodos SPDC. Fonte: Adaptado de Sharifzadeh (2013).

## 2.2 Formulação Geral do Projeto Simultâneo de Processos e de Sistema de Controle

Os métodos de otimização simultânea de aspectos econômicos e do controlador propõem o estudo da dinâmica do processo, desde suas etapas iniciais, com o intuito de obter plantas que sejam mais fáceis de controlar. Essas metodologias abordam temas como a controlabilidade, a seleção e sintonia da estrutura de controle adequada, análise de propriedades similares de projetos alternativos (gerados a partir de uma avaliação econômica preliminar), a formulação de uma estrutura de otimização apropriada e um algoritmo eficiente de solução do problema. Muitas estratégias foram propostas na literatura e variam em nível de complexidade e nas considerações impostas para a solução do problema de otimização (VEGA *et al.*, 2014b; YUAN *et al.*, 2012).

A formulação desse problema de otimização simultâneo considera a integração do projeto de processos em estado estacionário e seu sistema de controle. A solução é um conjunto que determina a estrutura e disposição dos equipamentos dos processos, parâmetros de dimensionamento, condições operacionais economicamente viáveis, a estrutura de controle e a sintonia ótima do controlador na presença de perturbações e incertezas. De modo geral, a função objetivo a ser minimizada é uma função de múltiplos objetivos, como apresentada pela Equação (1) (YUAN *et al.*, 2012).

$$\min_{\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}, \mathbf{v}} \phi_{SPDC}(\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}, \mathbf{v}) = \begin{bmatrix} \phi_{eco}(\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}) \\ \phi_{din}(\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}, \mathbf{v}) \end{bmatrix} \quad (1)$$

A função objetivo a ser minimizada incorpora a combinação de custos operacionais e econômicos ( $\phi_{eco}$ ) com custos dinâmicos ( $\phi_{din}$ ), resultando em uma função de múltiplos objetivos. Nesta formulação,  $\dot{\mathbf{x}}$  é o vetor de estados do processo,  $\mathbf{y}$  é o vetor das variáveis de saída de dimensão  $n_y$ ,  $\mathbf{u}$  é um vetor de dimensão  $n_u$  que representa as variáveis de entrada,  $\mathbf{p}$  é o vetor de variáveis do projeto invariantes no tempo e  $\mathbf{v}$  é o vetor que contém os parâmetros do sistema de controle.

O problema possui como restrição as equações e inequações não lineares do sistema, por considerações econômicas e de aspectos de controle, conforme apresentadas pelas Equações (2) a (9).

$$\mathbf{f}(\dot{\mathbf{x}}(t), \mathbf{x}(t), \mathbf{p}, \mathbf{v}, \mathbf{y}(t), \mathbf{u}(t)) = 0 \quad (2)$$

$$\mathbf{g}(\mathbf{x}(0), \mathbf{p}, \mathbf{v}, \mathbf{y}(0), \mathbf{u}(0)) = 0 \quad (3)$$

$$\mathbf{h}(\mathbf{x}(0), \mathbf{p}, \mathbf{v}, \mathbf{y}(0), \mathbf{u}(0)) \leq 0 \quad (4)$$

$$\mathbf{x}_{\min} \leq \mathbf{x}(t) \leq \mathbf{x}_{\max} \quad (5)$$

$$\mathbf{y}_{\min} \leq \mathbf{y}(t) \leq \mathbf{y}_{\max} \quad (6)$$

$$\mathbf{u}_{\min} \leq \mathbf{u}(t) \leq \mathbf{u}_{\max} \quad (7)$$

$$\mathbf{p}_{\min} \leq \mathbf{p} \leq \mathbf{p}_{\max} \quad (8)$$

$$\mathbf{v}_{\min} \leq \mathbf{v} \leq \mathbf{v}_{\max} \quad (9)$$

O vetor de variáveis de estado  $\dot{\mathbf{x}}$  e de suas derivadas  $\dot{\mathbf{x}}$  são geralmente descritos pelo conjunto de equações diferenciais e representados pelo modelo do processo em malha fechada com o algoritmo de controle utilizado ( $\mathbf{f}$ ). As restrições relacionadas ao processo podem assumir a forma de igualdades tipicamente representadas pelas equações algébricas do modelo do processo em condição inicial ( $\mathbf{g}(\mathbf{x}(0), \mathbf{u}(0))$ ) e pelas restrições de desigualdade, representadas pelas restrições físicas, de segurança, qualidade, etc. ( $\mathbf{h}$ ) (HULTGREN; IKONEN; KOVÁCS, 2019; KOLLER; RICARDEZ-SANDOVAL, 2017). O modelo fenomenológico do processo pode obtido a partir dos balanços de matéria e energia e das equações constitutivas. Usualmente esse modelo é uma função não linear das variáveis do sistema (LUYBEN, 1996). Vale destacar que as EDOs do modelo fenomenológico são discretizadas, utilizando um tempo de amostragem ( $\Delta t$ )

Outras restrições sob as quais o problema está sujeito são: o algoritmo de controle MPC e a condição de estabilidade do sistema em malha fechada, como descrito na seção 3.1. As restrições devem ser satisfeitas em todo o período de operação do processo e para qualquer variação possível nas perturbações do processo (RICARDEZ-SANDOVAL; BUDMAN; DOUGLAS, 2009).

A formulação matemática do problema de otimização simultâneo depende de aspectos relacionados ao escopo do problema, das técnicas usadas para introduzir as medidas de controlabilidade (e outras propriedades relacionadas ao seu desempenho dinâmico) ao problema de projeto e outras propriedades, da estratégia e estrutura de controle escolhida e o tratamento ou não de perturbações e/ou incertezas nos parâmetros (VEGA *et al.*, 2014b).

Na solução destes problemas de otimização estão envolvidas duas classes de variáveis: as estruturais, como por exemplo, configuração do processo e seleção das variáveis controladas e manipuladas; as paramétricas, variáveis relacionadas a dimensão dos equipamentos, condições de operação, sintonia dos controladores. De acordo com o tipo de variáveis a serem otimizadas, os recursos mais utilizados na busca de solução para estes problemas são os métodos para resolver problemas de programação não linear (NLP, do inglês *Nonlinear Programming*), programação não linear inteira-mista (MINLP), a otimização dinâmica inteira-mista (MIDO) e os métodos de otimização global (SHARIFZADEH, 2013; VEGA *et al.*, 2014b).

As diferentes metodologias SPDC baseadas no problema de otimização integrado são classificadas primeiramente de acordo com os métodos utilizados para avaliar a controlabilidade ou outras propriedades do sistema de controle relacionadas ao seu desempenho dinâmico. Em virtude do grande número de trabalhos que lidam com o desenvolvimento dessas metodologias, outros critérios foram usados ao longo do tempo para classificar de acordo com o foco e considerações efetuadas na concepção do projeto (VEGA *et al.*, 2014b). Embora os aspectos e características básicas do problema de projeto estejam presentes em todos, a classificação busca diferenciar o problema SPDC de acordo com as diferentes esferas do problema, a saber, o escopo do problema de projeto, as estratégias de controle, o tratamento de perturbações e incertezas e a formulação do problema de otimização.

### **2.3 Métodos baseados em índices de controlabilidade e propriedades relacionadas**

Os métodos baseados em alternativas de projetos utilizam medidas de controle em sua busca pela melhor configuração de projeto de processos e da estrutura de controle. Entretanto, uma desvantagem importante é que essa medida diz respeito apenas a um determinado fator limitante de controle, e em seu esforço máximo na busca por alcançá-lo, elas podem apenas destacar situações em que a capacidade de controlar o processo é perdida. Reconhecendo essa e outras limitações, os pesquisadores têm estudado abordagens que incorporam essas medidas de controle em um problema de projeto de processo, resultando em uma otimização de múltiplos objetivos (SHARIFZADEH, 2013).

Dentro desse escopo, existem alguns métodos que utilizam métricas de controlabilidade na formulação de um problema simultâneo. Eles são denominados métodos de otimização baseados em índices de controlabilidade e buscam combinar o projeto estacionário, baseado em aspectos econômicos com o custo relacionado a um indicador de desempenho dinâmico da planta. Nessa abordagem, índices como a matriz de ganhos relativos e o número condicional são utilizados para quantificar o desempenho do sistema em malha fechada. Esses índices clássicos podem ser facilmente incluídos como objetivos ou até mesmo restrições na formulação do problema de otimização, resultando em um problema que combina ambos objetivos (econômicos e dinâmicos) (VEGA *et al.*, 2014b; YUAN *et al.*, 2012).

#### 2.3.1 Métodos baseados nos índices de controlabilidade

Em um dos trabalhos pioneiros em metodologias SPDC, Lenhoff e Morari (1982) propuseram uma abordagem por meio da qual o índice da integral do erro quadrático (ISE, do inglês *Integral Square Error*) foi utilizado para quantificar o desempenho dinâmico do sistema. A otimização buscou minimizar simultaneamente aspectos econômicos e dinâmicos em uma única função

objetivo. A proposta considerada pelos autores foi aplicada em um estudo de caso de colunas de destilação com integração energética e os resultados demonstraram sua utilidade. Contudo, a manutenção satisfatória da operabilidade dinâmica satisfatória em um ambiente propício a incerteza apontou para a necessidade de um tratamento mais rigoroso do tópico. Palazoglu e Arkun (1986) propuseram uma estrutura de múltiplos objetivos, que fez uso extensivo de decomposição em valores singulares e, diferentemente dos trabalhos iniciais, se preocuparam com a melhoria dinâmica operacional em virtude de incertezas no processo. O problema final foi explorado pelo uso de técnicas de programação semi-infinitas não lineares e os índices de operabilidade dinâmica foram usados como restrições.

Além das análises concentradas em variabilidade dos processos, a estabilidade é uma característica muito importante, e por si só pode decidir o destino da operação. Blanco e Bandoni (2003) propuseram uma análise por meio de uma medida de controle baseada nos autovalores da matriz Jacobiana do modelo dinâmico, avaliando a sua estabilidade dinâmica. O objetivo da metodologia foi formular e resolver o problema do projeto de processo químico no qual a dinâmica do sistema é considerada a partir de uma abordagem de otimização desses autovalores. Para os autores, embora a operação de estado estacionário instável em malha aberta possa ser viável de ser controlada por controladores feedback, ela é indesejável e deve ser evitada pelo projeto apropriado.

Os métodos acima são prioritariamente aplicados a um modelo linearizado, o que pode ser justificado pela ideia de um compensador não linear que remove alguns aspectos do comportamento não linear do sistema. Entretanto, ao realizar essas considerações, as estratégias são consideradas eficientes apenas para controle regulatório nas proximidades de um estado estacionário. Além disso, muitos desses índices não forneceram uma clara relação com a economia do processo e as abordagens não foram suficientes para tratar um problema altamente não linear (DAVID *et al.*, 2004).

### 2.3.2 Métodos baseados na dinâmica do modelo não linear

Como é de conhecimento, os processos químicos, em sua maioria, são não lineares e podem possuir características de comportamento de fase não mínima e multiplicidade de estados estacionários. Dessa forma, técnicas baseadas na simulação de modelos dinâmicos para processos não lineares foram propostas para introduzi-los no problema de otimização integrado de projeto de processos e de seu sistema de controle. Tais abordagens representam de forma satisfatória as não linearidades dos processos e possibilitam a avaliação direta dos requisitos de desempenho a partir dos parâmetros do projeto e do controlador. Outros fatores importantes são a consideração do efeito das perturbações na formulação do problema e o perfil crítico que produz o cenário do pior caso, que pode também ser considerado (RICARDEZ-SANDOVAL; BUDMAN; DOUGLAS, 2009; SHARIFZADEH, 2013).

Em Mohideen, Perkins e Pistikopoulos (1996), uma estrutura simultânea foi empregada com o objetivo de obter uma configuração ótima para a planta e lidar com incertezas paramétricas e perturbações do processo no modelo não linear. Os autores propuseram um algoritmo de decomposição iterativa em que a solução alternasse entre um conjunto de alternativas para as estruturas de projeto e de controle. A abordagem foi ilustrada para um problema de tanque de mistura e uma coluna de destilação, demonstrando o potencial da abordagem em relação às técnicas sequenciais. O tratamento de incertezas serviu como base para estudos de abordagens unificando as etapas de projeto e controle sob essas condições.

Silva-Beard e Flores-Tlacuahuac (1999) detectaram várias regiões do comportamento não linear para um reator de polimerização de metacrilato de metila. Esta informação foi usada para estudar como as alterações no projeto e/ou operação afetavam o comportamento linear do reator. Por meio deste estudo foi possível remover regiões nas quais o controle em malha fechada fosse demasiadamente difícil, além de detectar regiões inviáveis para operação. Os autores concluíram que, no caso por eles considerado, a presença de regiões instáveis não apresentou sérios problemas de controle, contudo, a presença de

multiplicidade de entradas pode dar origem a zeros positivos na função de transferência, limitando a velocidade da resposta do sistema em malha fechada.

Pintarič e Kravanja (2004) apresentaram uma estratégia sequencial em dois passos para síntese de processos em que a flexibilidade e a operabilidade são consideradas na formulação do problema de otimização. Em ambas etapas, o valor esperado da função objetivo foi aproximado por um método que depende da otimização no ponto básico central. Diferentemente de Silva-Beard e Flores-Tlacuahuac (1999), a característica mais importante do modelo estocástico utilizado foi o fato de que seu tamanho depender principalmente do número de variáveis de projeto e não do número de parâmetros incertos.

Em Revollar *et al.* (2010), os autores fizeram uso de um controle MPC não linear, argumentando que os controladores com modelos lineares poderiam apresentar problemas de estabilidade e robustez na presença de não linearidades. Como esperado, o uso da técnica de controle avançado representou avanço devido às vantagens em relação aos controladores PID convencionais.

De acordo com Sharifzadeh (2013), medidas de não linearidade para o processo indicam, ainda que de maneira precoce, durante as etapas iniciais de projeto, condições para decidir se um controlador linear é suficiente ou se é necessário utilizar um controlar o processo com controlador não linear, visando a obtenção do desempenho ótimo. Além disso, as medidas fornecem também informações para o diagnóstico de falhas durante a operação. Contudo, ainda há poucos trabalhos que exploram essas medidas, sugerindo uma área de pesquisa com futuro extenso.

Entretanto, o uso direto de modelos dinâmicos não lineares do sistema aliados às decisões e variáveis discretas, podem resultar em problemas complexos e em alguns casos intratáveis. Para aliviar esse problema, uma redução da complexidade combinatória do problema de otimização pode ser obtida por métodos baseados em parâmetros de robustez de controle. Esses métodos consideram as incertezas dos processos reais e fornecem propriedades de robustez para as plantas obtidas e variabilidade do pior caso. O modelo do processo é representado como modelos com incertezas nos parâmetros que podem ser usados para calcular limites nas variáveis envolvidas na função

objetivo e as restrições do problema em questão (HUUSOM, 2015; RICARDEZ-SANDOVAL; BUDMAN; DOUGLAS, 2009a; YUAN *et al.*, 2012).

### 2.3.3 Métodos baseados na análise de robustez

Mönnigmann e Marquardt (2005) propuseram medidas robustas pelo cálculo da distância entre um ponto de operação candidato e os chamados pontos críticos. A novidade foi o cálculo automático e atualizado dos pontos críticos, importante para processos em que não existe informação a priori sobre a existência e localização dos pontos críticos e a sistemas grandes com várias equações.

Francisco, Vega e Álvarez (2011), por sua vez, garantiram a estabilidade do processo pelo uso de um controlador MPC de horizonte infinito. A robustez foi considerada por meio de normas baseadas em índices de controlabilidade bem como uma condição de desempenho robusto em uma estratégia de múltiplos modelos. Sanchez-Sanchez e Ricardez-Sandoval (2013a) incluíram um teste de estabilidade robusto (baseado na função quadrática de Lyapunov) garantindo que o projeto ideal fosse estável mesmo diante de perturbações. Sanchez-Sanchez e Ricardez-Sandoval (2013b) consideraram uma metodologia que consistiu em estrutura de decomposição iterativa, incluindo uma análise da flexibilidade dinâmica, um teste de viabilidade robusto, uma análise de estabilidade nominal e um teste robusto de estabilidade assintótica com objetivo de encontrar fluxogramas ótimos para o processo.

A maioria das metodologias de integração de projeto de processos e da estrutura de controle possui como base o mesmo conceito-chave: determinar as realizações críticas nas perturbações e nos parâmetros do problema que produzem o maior desvio nas variáveis controladas. Esse procedimento exige enormes esforços do sistema de controle, que trabalha com o objetivo de manter o processo dentro de suas especificações, mesmo em virtude dessas condições. Esse cenário é conhecido como o pior caso e é nessas condições que o problema simultâneo age para projetar o esquema ótimo que acomoda o pior cenário sem violar restrições nas ações de controle ou nas variáveis controladas.

Contudo, essa abordagem pode ocasionar projetos com conservadorismo desnecessário e caros. Tendo em vista esses problemas, metodologias que incorporam a probabilidade de ocorrência do cenário de pior caso surgiram motivadas pela exigência de projetos economicamente viáveis (BAHAKIM; RICARDEZ-SANDOVAL, 2014).

#### 2.3.4 Métodos baseados em análise probabilística

Ricardez-Sandoval (2012) propôs um método com realizações aleatórias nas perturbações. Foi realizada uma análise de distribuição sobre a variabilidade do pior caso estimada por meio de funções de distribuição normal em um limite de probabilidade definido pelo usuário. Essas estimativas, por sua vez, foram utilizadas para avaliar restrições, desempenho dinâmico e economia do sistema para um reator de mistura perfeita (CSTR, do inglês *Continuous Stirred Tank Reactor*). Estudos comprovaram a eficiência computacional do método ao propor projeto ótimo em aspectos econômicos mesmo na presença de incertezas.

Bahakim e Ricardez-Sandoval (2014) desenvolveram uma metodologia de projeto de processos integrado a projeto de controle baseada em princípios de probabilidade para processos químicos na presença de incertezas. Além disso, os autores utilizaram um controlador MPC e buscaram determinar a variabilidade dinâmica do pior caso e determiná-la por meio de um índice probabilístico da variabilidade do pior caso.

Chan e Chen (2017) propuseram uma estrutura probabilística que usa o modelo de processo gaussiano para representar a incerteza na entrada. A variabilidade foi avaliada estatisticamente por meio de uma função gaussiana. A proposta foi aplicada e testada em um tanque de mistura e obteve êxito em manter o processo dentro de seus limites, mesmo na presença de perturbações.

A otimização com objetivos econômicos e de controle avaliados simultaneamente resulta em uma superestrutura e um desafio difícil para as atuais tecnologias de otimização dinâmica. É importante ressaltar que alguns aspectos dessa complexidade computacional podem ser atribuídos aos

controladores, o que torna sua escolha essencial em um problema simultâneo (RAFIEI; RICARDEZ-SANDOVAL, 2020; SHARIFZADEH, 2013).

## **2.4 Métodos baseados na estratégia de controle**

A literatura apresenta os sistemas de controle clássicos do tipo PID como aqueles que foram mais utilizados em problemas de projeto simultâneo, contudo novas aplicações têm apostado na utilização de técnicas de controle avançado, tais como o MPC. A forma com que os parâmetros dos controladores são introduzidos difere em cada problema: enquanto uns o incluem dentro da estrutura de otimização, outros são sintonizados de maneira empírica (SHARIFZADEH, 2013; VEGA *et al.*, 2014b). É importante ressaltar que a controlabilidade é uma propriedade inerente do processo e, sendo assim, independe do projeto do controlador. Isso implica que um controlador mais sofisticado não suprirá e resolverá o problema de um processo não controlável (MORARI, 1983). Outro ponto importante a se destacar é que não existe um consenso entre os estudos sobre requisitos para a escolha do tipo de controlador (SHARIFZADEH, 2013). Estudos direcionam para a simplicidade e robustez dos controladores clássicos, depreciando os avançados, em virtude principalmente da complexidade adicional ao problema integrado. Por outro lado, outros contrapõem a respeito das vantagens econômicas e do tratamento implícito de restrições observados nos controladores avançados, desprestigiando a abordagem convencional que faz uso de *setpoints* constantes em sua formulação (LUYBEN, 2004; RAWLINGS; STEWART, 2008; SKOGESTAD, 2009; STEPHANOPOULOS; NG, 2000).

### 2.4.1 Métodos de controle clássico

A maioria das abordagens iniciais tratou o problema utilizando controladores tradicionais do tipo PID. A razão é que esquemas de controle avançado, tais como o MPC, envolvem a solução de um problema de otimização *online*,

umentando a complexidade do algoritmo de otimização (SHARIFZADEH, 2013; VEGA *et al.*, 2014b).

Bahri, Bandoni e Romagnoli (1997) estudaram a interação do problema de projeto de processos e de seu sistema de controle utilizando aspectos de controlabilidade e flexibilidade de dois reatores CSTR em série com um controlador PI. A abordagem permitiu calcular informações necessárias a partir de um ótimo nominal, garantindo a viabilidade da operação em meio às perturbações. Bansal *et al.* (2003) apresentaram novas formulações e algoritmos baseados na decomposição em subproblemas primários, otimização dinâmica e programação linear inteira mista, visando a solução de problemas MIDO. Os métodos foram aplicados em colunas de destilação com controlador PI. As conclusões apontaram para um algoritmo com vantagens no tratamento e solução dos problemas grandes de engenharia usando ferramentas disponíveis, oferecendo progresso na solução de problemas mais realistas na área SPDC.

Panjwani *et al.* (2005) apresentaram o projeto integrado para uma planta de destilação reativa utilizando avanços até então recentes de problemas MIDO. Um modelo dinâmico de alta fidelidade foi usado para prever o comportamento do processo na presença de incertezas e o controle foi realizado por um controlador PI. Um sistema economicamente atraente e melhor controlador foram obtidos e os autores mostraram que foi possível garantir um resultado de 17% de economia em relação ao projeto original. De La Fuente e Flores-Tlacuahuac (2009) resolveram o problema simultâneo como uma programação não linear inteira mista usando a abordagem de otimização dinâmica simultânea, por meio de uma estratégia de decomposição. A metodologia foi testada para uma coluna de destilação binária controlada por um controlador PI e os resultados mostraram a capacidade da proposta, contudo o tempo de solução foi muito grande, por causa da forma de decomposição.

Diangelakis, Manthanwar e Pistikopoulos (2014) integraram os dois problemas visando alcançar objetivos de controle e econômicos de um sistema de cogeração movido a motores de combustão interna. O controle foi realizado por um controlador PI e comparado com a mesma abordagem de projeto, para a qual o controlador utilizado foi um MPC, sendo este último, como esperado, o único a garantir a observação das restrições.

As metodologias apresentadas acima conseguiram obter um ótimo nominal, garantindo a viabilidade da operação em meio às perturbações. Outra vantagem relatada foi a menor carga computacional desses algoritmos, permitindo aplicações em colunas de destilação e dos problemas de grande porte da engenharia, usando ferramentas disponíveis. De maneira geral, os projetos integrados apresentaram representativa economia, controlando as variáveis do processo na presença de incertezas e perturbações. Embora seja possível manter o sistema próximo aos valores desejados, houve ocasiões em que as restrições foram violadas (BAHRI; BANDONI; ROMAGNOLI, 1997; BANSAL *et al.*, 2003; DIANGELAKIS; MANTHANWAR; PISTIKOPOULOS, 2014; PANJWANI *et al.*, 2005). Tais situações, aliadas às características dos controladores avançados com respeito a desempenho econômico e tratamento de restrições, fizeram com que as abordagens que utilizam técnicas de controle avançado encontrassem cada vez mais relevância na literatura (FRANCISCO *et al.*, 2009; RAWLINGS; STEWART, 2008; SKOGESTAD, 2009; STEPHANOPOULOS; NG, 2000).

#### 2.4.2 Métodos de controle avançado

As limitações com relação às restrições e ao desempenho ótimo dos problemas com controle clássico podem ser superadas pela implementação de um controlador avançado, tais como os algoritmos MPC. Aplicações de estratégias de controle avançado têm sido apresentadas na literatura de metodologias SPDC como promissoras e um campo aberto de pesquisas (BERNAL *et al.*, 2018; FRANCISCO *et al.*, 2009; VEGA *et al.*, 2014b).

A maioria dos trabalhos considera modelos lineares na formulação do controlador, o que ajuda a diminuir a complexidade do problema de otimização, mas pode acarretar em projetos subótimos (BRENGEL; SEIDER, 1992; FRANCISCO *et al.*, 2009; GUTIERREZ *et al.*, 2014; LOEBLEIN; PERKINS, 1999; MANSOURI *et al.*, 2016a; SAKIZLIS; PERKINS; PISTIKOPOULOS, 2003b; STRUTZEL; BOGLE, 2016).

Brengel e Seider (1992) apresentaram uma abordagem que avaliou como o objetivo econômico determinava a capacidade de controle de cada projeto usando a resposta do sistema em malha fechada na presença de perturbação. A operação foi simulada com um algoritmo de controle MPC, aplicada a um processo de fermentação, em que uma simples otimização do lucro levava a projetos altamente restritos e instáveis. Os resultados demonstraram a eficiência da aplicação de controladores do tipo MPC na obtenção de projetos alternativos com melhor controlabilidade. Loeblein e Perkins (1999) avaliaram a otimização integrada de projeto e sistemas de controle. A lei de controle preditivo foi usada sem considerar restrições e foi analisada a variação das variáveis restritas do sistema em malha fechada sujeito a perturbações aleatórias. Com base nessa análise, a diferença entre o projeto e a restrição na presença de perturbações pode ser calculada e a análise econômica em conjunto com a dinâmica estabelecida. Diferentes estruturas para o sistema foram ser comparadas pelo do desempenho dinâmico, decidindo sobre o melhor projeto.

Sakizlis, Perkins e Pistikopoulos (2003) desenvolveram um método no qual um controlador baseado em programação paramétrica foi utilizado. A programação paramétrica buscou reduzir a complexidade do problema de otimização online do controle avançado. Os autores encontraram um controlador de fácil implementação com benefícios econômicos e operacionais significativos.

Francisco e Vega (2006) consideraram em seu procedimento um problema de otimização multiobjetivo não linear em que restrições foram inseridas, garantindo o desempenho ótimo em aspectos econômicos e dinâmico. As estruturas do processo e do controlador foram consideradas fixas. Em sua análise, os autores incluíram também um controlador preditivo linear multivariável com restrição e resolveram o problema em duas etapas iterativas. Posteriormente, Francisco *et al.* (2009) apresentaram um método para o projeto integrado de um processo de lodo ativado usando um controlador MPC multivariável. A estrutura do projeto e do controlador foram determinadas de maneira simultânea na busca da planta mais econômica e com índices de controle considerados satisfatórios. O problema de otimização foi resolvido utilizando algoritmo genético. Os autores usaram normas baseadas em índices de controlabilidade como um conjunto de restrições no problema de otimização

e não como um custo de um problema de múltiplos objetivos. Os resultados apontaram para a vantagem de utilizar uma estratégia de controle avançado em comparação às estratégias tradicionais.

Gutierrez *et al.* (2014) apresentaram uma abordagem simultânea na qual foi inserido um procedimento de seleção da estrutura de controle. O desempenho dinâmico foi calculado por meio de uma função objetivo que quantificou o custo da variabilidade, usando limites analíticos derivados de testes usados no projeto de controle robusto. A estrutura do controlador foi encontrada por meio do cálculo de custos de comunicação entre as variáveis manipuladas e controladas, com base nos parâmetros do controlador MPC e dos ganhos do processo.

Strutzel e Bogle (2016) apresentaram um índice econômico de otimização do controlador MPC, com objetivo de fornecer uma metodologia para comparar diferentes projetos e determinar o melhor, avaliando como eles podem ser controlados e otimizados por um MPC com restrições por zona. Os autores também avaliaram os efeitos das perturbações no índice de maneira a ilustrar como elas podem reduzir a rentabilidade, restringindo a capacidade do MPC de alcançar equilíbrio dinâmico perto das restrições do processo.

Em geral, quando uma metodologia foi orientada pela estratégia de controle a ser utilizada, os autores limitaram-se à escolha um processo e de uma estrutura de controle fixos, determinando somente os parâmetros do processo e da sintonia dos controladores. Tais pressupostos, juntamente com o alcance do problema, as métricas usadas para quantificar o controle e outras propriedades dinâmicas, bem como a ausência ou presença do tratamento de perturbações e incertezas no sistema têm definido a forma de apresentação do problema de otimização integrado (HUUSOM, 2015; RAFIEI; RICARDEZ-SANDOVAL, 2020; VEGA *et al.*, 2014b).

## **2.5 Métodos baseados na formulação do problema de otimização**

A literatura tem abordado a síntese do problema de otimização por meio de um procedimento em que uma função objetivo é avaliada via aspectos econômicos e da estrutura de controle. As decisões de projeto e de controle

foram separadas em dois subproblemas ou consideradas simultaneamente em uma única função objetivo na qual os objetivos econômicos e suas restrições estão relacionadas aos índices de desempenho dinâmico (VEGA *et al.*, 2014a; YUAN *et al.*, 2012).

Nestes tipos de problemas, a natureza dinâmica do processo foi considerada de modo que o problema de projeto se torna uma combinação de objetivos e formulado, por exemplo, como um problema MIDO (MOHIDEEN; PERKINS; PISTIKOPOULOS, 1996). As variáveis de otimização incluem todas as variáveis de projeto, *setpoints* e parâmetros dos controladores (VEGA *et al.*, 2014a; YUAN *et al.*, 2012). A função objetivo é minimizada no tempo e sujeita ao modelo dinâmico do processo, bem como às restrições operacionais. O objetivo é buscar o projeto de processo desejável e o desempenho de controle adequado (parâmetros do controlador) para minimizar o custo de capital e a soma dos custos relacionados à operação em um horizonte de tempo (YUAN *et al.*, 2012). Como a formulação matemática do procedimento resulta muitas vezes em um problema MIDO de grande escala, várias pesquisas foram realizadas nos últimos anos dedicadas ao desenvolvimento de estratégias de solução que pudessem reduzir os custos computacionais (SHARIFZADEH, 2013).

### 2.5.1 Formulações do tipo multiobjetivo

Luyben e Floudas (1994) incorporaram os problemas econômico e dinâmico em uma superestrutura de múltiplos objetivos do tipo MINLP. A solução que representa o melhor compromisso entre os dois objetivos foi encontrada e o procedimento proposto foi então aplicado na síntese de destilação binária. Nenhuma restrição foi considerada para calcular medidas de controlabilidade de malha fechada. O problema de otimização foi tratado de modo que o tipo de controlador fosse especificado *a priori* e os seus parâmetros foram calculados com base nos parâmetros de projeto desconhecidos.

Entretanto, encontrar o melhor controlador sem que a sua forma seja previamente identificada consiste em tratar o problema de otimização de forma aberta. Para resolver o problema da análise sistemática da interação entre o

projeto do processo e da estrutura de controle, Schweiger e Floudas (1998) simplificaram o problema de controle ótimo inteiro misto em um problema considerando apenas variáveis contínuas com equações diferenciais. Os autores concluíram o seu trabalho apontando para considerações de métricas de controlabilidade para sistemas não lineares e a necessidade de avaliar questões de incerteza de processo, controle robusto e análise de flexibilidade. Asteasuain *et al.* (2004) empregaram uma abordagem de otimização dinâmica inteira mista (MIDO) para realizar o projeto simultâneo em reatores de polimerização de estireno. Os resultados apresentaram a capacidade da metodologia integrada de incorporar decisões de controle no problema de otimização destes equipamentos, fornecendo uma melhor compreensão das interações do sistema, obtendo projetos mais controláveis. Entretanto, os autores partiram das premissas de que não havia perturbações ou incertezas do modelo para garantir a viabilidade das operações.

Trainor *et al.* (2013) trataram de sistemas dinâmicos com incertezas e incorporaram análises robustas de viabilidade e estabilidade, garantindo a operabilidade dinâmica do processo e a estabilidade assintótica, tornando o problema computacionalmente mais atrativo. Foi utilizada uma abordagem de perturbação geral e a formulação foi aplicada a um sistema de destilação ternária com modelo rigoroso.

Em Diangelakis *et al.* (2017), uma estrutura SPDC por meio de programação multi-paramétrica foi aplicada em quatro estudos de caso. Foram desenvolvidos controladores MPC que dependem dos parâmetros do projeto e são capazes de fornecer ações de controle ideais. A formulação resultou em uma etapa de otimização MIDO para a determinação do projeto ótimo do processo e de seu sistema de controle. Os autores consideraram a abordagem por meio de otimização de diferentes pontos de referência com base em critérios financeiros de médio prazo, buscando resolver o problema de determinar a operação de longo prazo do sistema com eficiência.

Nas abordagens anteriormente discutidas, as decisões entre a configuração de fluxograma e cada possível emparelhamento entre as variáveis manipuladas e controladas provocaram uma ampla gama de alternativas de projeto, descontinuidades no espaço de busca. Buscando reduzir a complexidade

combinatória desses projetos, uma formulação em que as decisões do projeto e de controle são separadas foi proposta, tornando-o mais tratável (YUAN *et al.*, 2012). De acordo com Huusom (2015), este tem sido o modo mais fácil de abordar o problema simultâneo de projeto de processos.

### 2.5.2 Formulação com subproblemas de otimização

No contexto de subproblemas de otimização, o problema foi formulado em dois níveis, resolvido por meio de uma abordagem sequencial de dois estágios (MALCOLM *et al.*, 2007). No primeiro nível (mestre), buscaram-se as decisões ótimas de projeto. No segundo nível, a busca concentrou-se no desempenho dinâmico, com base nas decisões obtidas na primeira etapa, uma estratégia de controle particular, por exemplo, MPC e seus parâmetros de sintonia. Observou-se que a escolha pela fixação de uma estratégia de controle elimina as decisões de selecionar estruturas de controle, reduzindo a complexidade do problema, muito embora a solução possa ser subótima (HUUSOM, 2015; MANSOURI *et al.*, 2016a; YUAN *et al.*, 2012). O principal objetivo desta abordagem foi incluir no problema de otimização leis de conservação, algoritmos de controle, segurança, equipamentos e requisitos de produção, custo operacional esperado e custo de capital (ANEESH *et al.*, 2016).

Malcolm *et al.* (2007) abordaram o problema integrado decompondo-o em dois níveis e reduzindo significativamente a complexidade do problema. O primeiro nível otimizou decisões de projeto, que uma vez realizadas, permitem a avaliação do desempenho dinâmico do processo usando esquemas de controle determinados. O método proposto delegou as decisões de controle para um subproblema de otimização que adapta os movimentos de controle adequados para um determinado projeto, de modo que as decisões de controle são incorporadas para cada projeto proposto, evitando a crescente combinação no número de alternativas de controle. Os autores sugeriram como etapas futuras a melhora nos métodos computacionais de determinação da flexibilidade do processo usando técnicas de otimização estocástica.

Moon, Kim e Linninger (2011a,b) estenderam a metodologia desenvolvida por Malcolm *et al.* (2007) para o estudo de um fluxograma contendo um reator e uma coluna, assegurando sua eficácia e capacidade em realizar o projeto e controle integrado de um processo mais realista. Os autores identificaram a necessidade de melhorar a qualidade de identificação para processos altamente não lineares por meio de mecanismos mais avançados, tais como o uso de controlador MPC, o que em contrapartida, pode tornar o algoritmo com mais custo computacional.

Zhou *et al.* (2015) utilizaram uma abordagem hierárquica para o problema de otimização formulado, resolvido de modo que o tamanho do problema tornasse tratável por meio de um procedimento sequencial de duas etapas. Nesta abordagem, os autores utilizaram um controlador PID que adaptou de modo adequado os movimentos de controle para cada projeto. Por fim, as decisões de controle foram incorporadas por meio de uma formulação dinâmica baseada em uma superestrutura que considerou o custo e a capacidade de controle e a metodologia proposta foi testada para dois processos químicos.

## **2.6 Desafios atuais**

Embora técnicas de controle avançado não sejam as mais utilizadas no problema de otimização integrada dos objetivos econômicos e dinâmicos, tais estratégias são atraentes, pois podem oferecer aumento de performance em ambos objetivos (RAFIEI; RICARDEZ-SANDOVAL, 2020; VEGA *et al.*, 2014b).

Os desafios atuais no desenvolvimento de metodologias SPDC podem ser classificados como: a) consideração de incertezas e perturbações; b) solução de problemas de múltiplos objetivos; c) aumento do problema de otimização dependendo do processo e das suposições levadas na sua formulação; d) tratamento de variáveis estruturais (inteiras); f) busca pelo ótimo global; e) a incorporação de estratégias de controle avançado (RAFIEI, 2020).

A maioria dos problemas apresentados na literatura trata a integração dos objetivos de controle e de projeto, com alguns trabalhos ultimamente considerando também os objetivos de planejamento, como a alteração nos preços dos produtos da reação (BURNACK *et al.*, 2019; DIANGELAKIS *et al.*,

2017). Buscando responder alguns dos desafios atuais, o uso dos controladores avançados apareceu como melhoria de desempenho do projeto integrado, uma vez que implementam ações ótimas de controle na planta pela solução de um problema de otimização (GUTIERREZ *et al.*, 2014; RAFIEI; RICARDEZ-SANDOVAL, 2020). Além disso, esses controladores foram caracterizados por lidar com interações e restrições do processo, que envolvem as variáveis de processo, fornecendo melhores projetos do que aqueles obtidos a partir de estratégias de controle descentralizadas, principalmente para sistemas complexos do ponto de vista do comportamento dinâmico (DIANGELAKIS; MANTHANWAR; PISTIKOPOULOS, 2014; RAFIEI; RICARDEZ-SANDOVAL, 2020).

Embora estratégias de controle avançado aumentem a complexidade da estrutura de projeto integrado, a escolha de um processo com o fluxograma, modelo e a estrutura de controle previamente definidos contrapõem essa limitação, oferecendo problemas mais fáceis de serem tratados, orientando a abordagem à aplicações de diferentes técnicas de controle avançado (FRANCISCO; VEGA; ÁLVAREZ, 2011; RAFIEI; RICARDEZ-SANDOVAL, 2020).

De maneira geral, as metodologias SPDC que utilizaram controladores avançados foram apresentadas de modo que a predição foi realizada por um modelo linearizado, obtido em torno de uma condição de estado estacionário (BAHAKIM; RICARDEZ-SANDOVAL, 2014; PALMA-FLORES; RAFIEI; RICARDEZ-SANDOVAL, 2020). Diante do desafio de representar as mudanças nas variáveis de decisão e incorporá-las na dinâmica do sistema, buscou-se avaliar uma estratégia adaptativa. A estratégia consistiu em linearizar o modelo do processo em torno de um estado estacionário, atualizando os parâmetros do modelo linear. De acordo com Rafiei e Ricardez-Sandoval (2020), usar um controlador preditivo não linear pode acrescentar desafios relacionados a um problema de otimização complexo e não convexo. Dessa forma, decidiu-se seguir pelo caminho da adaptação, através da atualização online dos parâmetros dos modelos ou pela combinação linear de modelos obtidos em diferentes regiões de operação do processo (DE OLIVEIRA; DE CARVALHO; ALVAREZ, 2019).

Na literatura há várias metodologias para a formulação do problema de otimização simultâneo e até o presente momento, pela análise realizada, nenhuma delas aborda a integração de projeto de processos e de seu sistema de controle conforme proposto neste trabalho.

### 3 CONTROLADOR PREDITIVO BASEADO EM MODELO (MPC)

Esta seção traz um breve estudo acerca dos fundamentos teóricos significativos para a metodologia. Para isso, serão apresentados a formulação teórica para a implementação de um controlador MPC com horizonte infinito e sua integração estável com a RTO em três camadas, bem como a estratégia de adaptação do modelo linear proposta neste trabalho.

#### 3.1 MPC Clássico

O algoritmo de controle preditivo baseado em modelo (MPC) não se refere a apenas uma estratégia específica de controle, e sim a uma família de controladores que usam um modelo explícito do processo para prever respostas futuras do sistema. Em cada intervalo de tempo, é realizada uma otimização do comportamento da planta pelo cálculo de uma sequência futura de ações de controle das variáveis manipuladas. O primeiro valor dessa sequência é enviado para a planta e todo o cálculo é repetido durante um horizonte de tempo (CAMACHO, E. F.; BORDONS, 2007; QIN; BADGWELL, 2003).

Os controladores MPC possuem uma história de sucesso em muitos setores da indústria química, de modo particular, na indústria petroquímica. Originalmente desenvolvido para atender às demandas de controle desse tipo de indústria, a tecnologia MPC é encontrada em uma ampla área de aplicação, sendo uma das poucas áreas que recebem interesse contínuo e simultâneo da indústria e da academia. O sucesso de sua aplicação está diretamente relacionado às suas características, dentre elas: ser uma técnica de conceitos básicos e intuitivos, facilitando o uso para pessoas com conhecimento limitado em controle; possui sintonia relativamente fácil; capacidade para controlar uma ampla gama de processos (simples e complexos, lineares e não lineares, estáveis e instáveis; SISO e MIMO); compensação intrínseca de tempo morto em sua estrutura preditiva; capacidade para lidar com restrições de todos os tipos em sua estrutura multivariável; otimização *online* de processos

(CAMACHO, E. F.; BORDONS, 2007; MACIEJOWSKI, 2002; SEBORG; THOMAS F. EDGAR, 2011; WANG, 2009).

Por meio de uma representação do comportamento dinâmico do processo (modelo matemático), os valores futuros das saídas são previstos e comparados com a trajetória de referência, gerando erros futuros que alimentam o otimizador (CAMACHO, E. F.; BORDONS, 2007; SEBORG; THOMAS F. EDGAR, 2011). O modelo usado no projeto do sistema de controle leva a diferentes formulações de controladores MPC. Por vezes, este é um modelo linear de espaço de estados, descrito no contexto de tempo discreto, como representado nas Equações (10) e (11) (WANG, 2009).

$$\tilde{\mathbf{x}}(k+1) = \tilde{\mathbf{A}}\mathbf{x}(k+1) + \tilde{\mathbf{B}}\mathbf{u}(k) \quad (10)$$

$$\mathbf{y}(k) = \tilde{\mathbf{C}}\tilde{\mathbf{x}}(k) \quad (11)$$

$\mathbf{x}$  é o vetor de estado (com dimensão  $nx$ ),  $\mathbf{y}$  é o vetor com as variáveis de saída (de dimensão  $ny$ ) e  $\mathbf{u}$  o vetor com as variáveis manipuladas (de dimensão  $nu$ ).  $k$  é o instante atual de tempo. As matrizes  $\tilde{\mathbf{A}}$  e  $\tilde{\mathbf{B}}$  são matrizes que descrevem as equações de transição de estados e  $\tilde{\mathbf{C}}$  a matriz das medidas (CAMACHO, E. F.; BORDONS, 2007). Essas matrizes são posteriormente substituídas na forma incremental pelas representações  $\mathbf{A}$ ,  $\mathbf{B}$  e  $\mathbf{C}$ , que possuem o mesmo significado. O modelo MPC na forma posicional, como apresentado pelas Equações (10) e (11) pode resultar em *offset* e uma forma de solucionar este problema é a implementação do modelo na forma incremental (ALVAREZ, 2012):

$$\begin{bmatrix} \Delta\tilde{\mathbf{x}}(k+1) \\ \mathbf{y}(k+1) \end{bmatrix} = \begin{bmatrix} \tilde{\mathbf{A}} & \mathbf{0}_{nx} \\ \tilde{\mathbf{C}}\tilde{\mathbf{A}} & \mathbf{I}_{ny} \end{bmatrix} \begin{bmatrix} \Delta\tilde{\mathbf{x}}(k) \\ \mathbf{y}(k) \end{bmatrix} + \begin{bmatrix} \tilde{\mathbf{B}} \\ \tilde{\mathbf{C}}\tilde{\mathbf{B}} \end{bmatrix} \Delta\mathbf{u}(k) \quad (12)$$

$$\mathbf{y}(k) = \begin{bmatrix} \mathbf{0}_{nx} & \mathbf{I}_{ny} \end{bmatrix} \begin{bmatrix} \Delta\tilde{\mathbf{x}}(k) \\ \mathbf{y}(k) \end{bmatrix} \quad (13)$$

Em que  $\Delta\mathbf{u} = \mathbf{u}(k) - \mathbf{u}(k-1)$ . O MPC resolve, a cada intervalo de tempo, um problema de otimização, que dentre as muitas formulações, pode ser apresentado através da Equação (14) (SEBORG; THOMAS F. EDGAR, 2011).

$$\begin{aligned} \min J(k) = & \sum_{j=0}^p (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) \\ & + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) \end{aligned} \quad (14)$$

Sujeito às Equações (12), (13) e às Equações (15) a (17).

$$\mathbf{y}_{\min} \leq \mathbf{y}(k+j|k) \leq \mathbf{y}_{\max}, j = 0, 1, \dots, p \quad (15)$$

$$\mathbf{u}_{\min} \leq \mathbf{u}(k+j|k) \leq \mathbf{u}_{\max}, j = 0, 1, \dots, m-1 \quad (16)$$

$$\Delta \mathbf{u}_{\min} \leq \Delta \mathbf{u}(k+j|k) \leq \Delta \mathbf{u}_{\max}, j = 0, 1, \dots, m-1 \quad (17)$$

Essas equações representam o modelo de predição do controlador, e os limites operacionais das variáveis controladas, manipuladas e no esforço de controle requerido pelo controlador (CAMACHO, E. F.; BORDONS, 2007). Nestas equações,  $\mathbf{y}(k+j|k)$  é o vetor de predição das variáveis de saída do sistema no instante  $k+j$ , medido no instante  $k$ ,  $\mathbf{y}^{sp}$  é o vetor com os valores de *setpoints* para as saídas controladas. O vetor  $\Delta \mathbf{u}(k+j|k)$  representa a solução que contém a sequência ótima de ações de controle encontrada pelo otimizador. Contudo, no MPC, aplica-se ao processo somente a primeira ação desta sequência ( $\Delta \mathbf{u}(k|k)$ ). Os parâmetros  $p$  e  $m$  são os horizontes de predição e de controle, respectivamente.  $\mathbf{Q}$  e  $\mathbf{R}$  são matrizes diagonais positivas definidas que contêm os pesos relacionados aos erros das saídas controladas em relação ao seu *setpoint* e os pesos relacionados aos esforços realizados pelo controlador nas variáveis manipuladas (QIN; BADGWELL, 2003).

Quando os estados não podem ser medidos ou possuem medidas afetadas por ruídos, um observador é incorporado para atualizar os estados como uma função erro entre as saídas preditas e as saídas do sistema. A Equação (18) representa a ação de realimentação a partir do processo, baseada nos valores medidos das saídas. Uma forma de representar o observador de estados é dada pela Equação (19). Este observador usa medições online (contaminadas com ruídos e incertezas) e gera resultados que tendem a aproximar as quantidades medidas aos valores reais das variáveis (QIN; BADGWELL, 2003).

$$\mathbf{y}_p(k) = \mathbf{y}_{medido}(k) \quad (18)$$

$$\mathbf{x}(k) = \mathbf{x}(k-1) + \mathbf{K}_F (\mathbf{y}_p(k) - \mathbf{C}\mathbf{x}(k-1)) \quad (19)$$

Em que  $\mathbf{K}_F^{n_x \times n_y}$  é a matriz ou ganho de Kalman, que tem a função de distribuir as disparidades encontradas entre os valores das variáveis de saída do sistema  $\mathbf{y}_p(k)$  e os valores das variáveis previstas pelo modelo  $\mathbf{C}\mathbf{x}(k-1)$ .  $\mathbf{K}_F^{n_x \times n_y}$  é calculada em 2 etapas (previsão e correção). Na previsão, o filtro realiza uma estimativa atual (estimativa *a priori*) da variável a partir da informação no tempo anterior e na correção, o filtro de Kalman usa medidas do processo para corrigir esta estimativa, calculando a estimativa *a posteriori* melhorada (XAVIER, 2011)..

Entretanto, ainda que possua virtudes, o MPC na forma incremental também apresenta inconvenientes ao projeto de um controlador robusto, pois, em muitos casos, a introdução de polos integradores artificiais no sistema pode acarretar em um modelo resultante não estável (ODLOAK, 2004).

A estabilidade do sistema em malha fechada é uma característica essencial em aplicações de controladores MPC para processos industriais (ALVAREZ; ODLOAK, 2012). O objetivo nestas aplicações é projetar um controlador estável independente das condições de operação, que costumam influenciar os valores dos parâmetros do modelo e dos parâmetros de sintonia (RODRIGUES; ODLOAK, 2003)

Em algoritmos MPC que desconsideram as restrições, a lei de controle é resolvida de forma analítica e uma avaliação de estabilidade nominal pode ser realizada observando os módulos dos valores próprios da matriz  $(\mathbf{A} + \mathbf{B}\mathbf{K}_{MPC})$ , que representa o espaço de estados do sistema discreto em malha fechada. Nesta definição,  $\mathbf{K}_{MPC}$  é o ganho do controlador MPC obtido pela solução analítica da Equação (14) sem restrições de desigualdade, e ele depende dos parâmetros de sintonia do controlador. Portanto, a estabilidade é definida quando esses valores estão dentro do círculo unitário do plano complexo (BAHAKIM; RICARDEZ-SANDOVAL, 2014):

$$|\lambda_i(\mathbf{A} + \mathbf{B}\mathbf{K}_{MPC})| < 1, i = 1, \dots, n_x \quad (20)$$

A inequação apresentada em (20) encontra utilidade e garante estabilidade nominal apenas para um controlador MPC convencional sem restrições.

Contudo, ao considerar as restrições impostas pelo processo o ganho  $\mathbf{K}_{MPC}$  não pode mais ser obtido por uma solução analítica do problema e muda a cada instante de amostragem (WANG, 2009).

Existem algumas de estratégias de controle para garantir a estabilidade robusta e nominal da malha de controle fechada de um sistema de controle preditivo baseado em modelo com restrições (BURNAK *et al.*, 2019; DIANGELAKIS *et al.*, 2017; MANSOURI *et al.*, 2016b). Dentre estas alternativas, a literatura apresenta metodologias que usam uma formulação em que o modelo considera a identificação das perturbações e outras que adotam um MPC de horizonte infinito, que garante estabilidade independente da escolha dos parâmetros de sintonia (ODLOAK, 2004; PANNOCCHIA; RAWLINGS, 2003).

### 3.2 MPC de horizonte infinito (IHMPC)

Um equacionamento possível de um controlador MPC de horizonte infinito (IHMPC, do inglês *Infinite Horizon Model Predictive Control*) é descrito com base em um modelo de espaço de estados no contexto de tempo discreto. Odloak (2004) apresentou um modelo para essa proposta de controlador, denominado OPOM (do inglês *Output Prediction Oriented Model*), que possui estabilidade nominal e tem como característica ser livre de erro de estado estacionário (*offset*). Além disso, o modelo OPOM apresenta boas características para tratar com problemas práticos como tempo morto, perturbação e comportamento dinâmico variável (CARRAPIÇO *et al.*, 2009; ODLOAK, 2004).

Na prática, um sistema de múltiplas entradas e múltiplas saídas (MIMO) pode ser representado por uma função de transferência ( $G_{i,j}(s)$ ) relaciona as várias entradas com as saídas do processo (ODLOAK, 2004).

$$G_{i,j}(s) = \frac{b_{i,j,0} + b_{i,j,1}s + \dots + b_{i,j,nb}s^{nb}}{1 + a_{i,j,1}s + \dots + a_{i,j,na}s^{na}} \quad (21)$$

Para a qual,  $na$  representa o número de polos do sistema (as raízes do polinômio do denominador) e  $nb$  o número de zeros do sistema (as raízes do polinômio do numerador da função de transferência). Um sistema realizável deve

respeitar a seguinte condição:  $\{na, nb \mid nb < na\}$  (ODLOAK, 2004; SEBORG; THOMAS F. EDGAR, 2011). A resposta ao degrau no instante  $k$ , para um período de amostragem ( $\Delta t$ ), pode ser calculada através da seguinte expressão:

$$S_{i,j}(k) = d_{i,j}^0 + \sum_{l=1}^{na} [d_{i,j,l}^d] e^{r_{i,j,l}k\Delta t} \quad (22)$$

Nesta equação, as variáveis  $d^0, d_i^d, \dots, d_{na}^i$  corresponde aos coeficientes de expansão parcial e as variáveis  $r_{i,j}, r_{i,j,1}, \dots, r_{i,j,na}$ , os polos da função de transferência do sistema (CARRAPIÇO; ODLOAK, 2005). Este modelo tem origem na forma analítica da resposta ao degrau, que pode ser associada com um modelo em função de transferência. Por meio dos coeficientes desta forma analítica, originam-se os estados do modelo de espaço de estados OPOM, representados de acordo com as Equações (23) e (24) (ODLOAK, 2004).

$$\begin{bmatrix} \mathbf{x}^s(k+1) \\ \mathbf{x}^d(k+1) \end{bmatrix} = \begin{bmatrix} \mathbf{I}_{ny} & 0 \\ 0 & \mathbf{F} \end{bmatrix} \begin{bmatrix} \mathbf{x}^s(k) \\ \mathbf{x}^d(k) \end{bmatrix} + \begin{bmatrix} \mathbf{D}^0 \\ \mathbf{D}^d \mathbf{F} \mathbf{N} \end{bmatrix} \Delta \mathbf{u}(k) \quad (23)$$

$$\mathbf{y}(k) = \begin{bmatrix} \mathbf{I}_{ny} & \mathbf{\Psi} \end{bmatrix} \begin{bmatrix} \mathbf{x}^s(k) \\ \mathbf{x}^d(k) \end{bmatrix} \quad (24)$$

Neste modelo, os estados são tratados como compostos por dois componentes: o vetor de estados integradores gerados pela forma incremental do modelo ( $\mathbf{x}^s$ ), de dimensão  $ny$  (número de saídas) e o vetor de estados ou modos estáveis ( $\mathbf{x}^d$ ), de dimensão  $nd$  (multiplicação do número de saídas, pelo número de entradas, pelo maior grau do polinômio do denominador das funções de transferência, ou seja,  $nd = ny \times nu \times na$ ) (CARRAPIÇO; ODLOAK, 2005; STRUTZEL, 2014).

Além disso, as seguintes matrizes, que recebem os parâmetros obtidos pela expansão das funções de transferências em frações parciais, são usadas para a etapa de otimização do IHMPC (ODLOAK, 2004).

$$\mathbf{F} = \text{diag} \left( \begin{array}{cccc} e^{r_{1,1,1}\Delta t} & \dots & e^{r_{1,1,na}\Delta t} & \dots & e^{r_{1,nu,1}\Delta t} & \dots & e^{r_{1,nu,na}\Delta t} & \dots \\ e^{r_{ny,1,1}\Delta t} & \dots & e^{r_{ny,1,na}\Delta t} & \dots & e^{r_{ny,nu,1}\Delta t} & \dots & e^{r_{ny,nu,na}\Delta t} & \dots \end{array} \right) \quad (25)$$

$$\mathbf{D}^0 = \begin{bmatrix} d_{1,1}^0 & \cdots & d_{1,nu}^0 \\ \vdots & \ddots & \vdots \\ d_{ny,1}^0 & \cdots & d_{ny,nu}^0 \end{bmatrix} \quad (26)$$

$$\mathbf{D}^d = \text{diag} \left( d_{1,1,1}^d \cdots d_{1,1,na}^d \cdots d_{1,nu,1}^d \cdots d_{1,nu,na}^d \cdots \right. \\ \left. d_{ny,1,1}^d \cdots d_{ny,1,na}^d \cdots d_{ny,nu,1}^d \cdots d_{ny,nu,na}^d \right) \quad (27)$$

$$\mathbf{N} = \begin{bmatrix} J_1 \\ \vdots \\ J_{ny} \end{bmatrix} \quad (28)$$

$$\mathbf{\Psi} = \begin{bmatrix} \Phi & & \\ & \ddots & \\ & & \Phi \end{bmatrix}, \mathbf{\Psi} \in \mathbb{R}^{ny \times nd} \quad \Phi \in [1 \cdots 1] \quad (29)$$

$$\mathbf{J} \in \mathbb{R}^{nu \times na \times nu} \quad (30)$$

$$\begin{bmatrix} 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 0 & \cdots & 0 \\ & & \ddots & \\ 0 & 0 & \cdots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}$$

Em cada intervalo de tempo, o IHMPC resolve o problema de otimização da Equação (31), sujeito às restrições do processo, obtendo uma ação de controle ótima e garantindo o desempenho adequado do processo, caso um modelo adequado esteja disponível (ODLOAK, 2004).

$$\min_{\Delta \mathbf{u}(k)} J(k) = \sum_{j=1}^{\infty} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) \\ + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) \quad (31)$$

A partir desta equação, pode-se separar o primeiro termo em duas partes: uma que considera os erros do tempo zero até o final do horizonte de controle e outra que considera do ponto seguinte ao horizonte de controle até o infinito, de modo que:

$$\begin{aligned}
\min_{\Delta \mathbf{u}(k)} J(k) &= \sum_{j=1}^m (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) \\
&+ \sum_{j=m+1}^{\infty} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) \\
&+ \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k)
\end{aligned} \tag{32}$$

Considerando esta forma de apresentar a função objetivo e o modelo OPOM, apresentado nas Equações (23) e (24), o termo somatório até o infinito pode ser desenvolvido da seguinte maneira:

$$\begin{aligned}
&\sum_{j=m+1}^{\infty} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) = \\
&\sum_{j=1}^{\infty} (\mathbf{x}^s(k+m|k) - \mathbf{y}^{sp} + \Psi \mathbf{F}^j \mathbf{x}^d(k+m|k))^T \mathbf{Q} \\
&\sum_{j=1}^{\infty} (\mathbf{x}^s(k+m|k) - \mathbf{y}^{sp} + \Psi \mathbf{F}^j \mathbf{x}^d(k+m|k))
\end{aligned} \tag{33}$$

Observa-se que nesta soma infinita o termo  $\mathbf{x}^s(k+m|k) - \mathbf{y}^{sp}$  não depende do índice  $j$  e, portanto, deve ser igualado a zero para manter o objetivo de controle limitado, ou seja, impedir que a função objetivo cresça indefinidamente. Assim, torna-se necessário incluir a seguinte restrição no problema de otimização do IHMPC:

$$\mathbf{x}^s(k+m|k) - \mathbf{y}^{sp} = 0 \tag{34}$$

Por meio da inclusão da Equação (34), a Equação (33) pode ser simplificada, e apresentada de acordo com a Equação (35).

$$\begin{aligned}
&\sum_{j=m+1}^{\infty} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) = \\
&\sum_{j=1}^{\infty} \mathbf{x}^d(k+m|k)^T (\mathbf{F}^j)^T \Psi^T \mathbf{Q} \Psi \mathbf{F}^j \mathbf{x}^d(k+m|k)
\end{aligned} \tag{35}$$

Para sistemas estáveis,  $\lim_{j \rightarrow \infty} \mathbf{F}^j = 0$  e então, a soma infinita do lado direito da Equação (35) pode ser reduzida para um único termo:

$$\sum_{j=1}^{\infty} \mathbf{x}^d(k+m|k)^T (\mathbf{F}^j)^T \Psi^T \mathbf{Q} \Psi \mathbf{F}^j \mathbf{x}^d(k+m|k) = \mathbf{x}^d(k+m|k)^T \bar{\mathbf{Q}} \mathbf{x}^d(k+m|k) \tag{36}$$

Em que  $\bar{\mathbf{Q}} \in \mathbb{R}^{nd \times nd}$  é a solução da seguinte equação de Lyapunov para o sistema discreto apresentado nas Equações (23) e (24).

$$\bar{\mathbf{Q}} - \mathbf{F}^T \bar{\mathbf{Q}} \mathbf{F} = \mathbf{F}^T \boldsymbol{\Psi}^T \mathbf{Q} \boldsymbol{\Psi} \mathbf{F} \quad (37)$$

Dessa forma, a função objetivo do controlador IHMPC, Equação (32), pode ser reescrita como:

$$\begin{aligned} \min_{\Delta \mathbf{u}(k)} J(k) &= \sum_{j=1}^m (\mathbf{y}(k+j|k) - \mathbf{y}^{sp})^T \mathbf{Q} (\mathbf{y}(k+j|k) - \mathbf{y}^{sp}) \\ &+ \mathbf{x}^d(k+m|k)^T \bar{\mathbf{Q}} \mathbf{x}^d(k+m|k) + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) \end{aligned} \quad (38)$$

Para obter uma expressão mais simples para o objetivo de controle acima, as Equações (23) e (24) podem ser usadas para estimar os estados e a saídas em tempos de amostragens futuros, como nas Equações.

$$\mathbf{y}(k+j|k) = \mathbf{x}^s(k+m|k) + \boldsymbol{\Psi} \mathbf{x}^d(k+m|k) \quad (39)$$

$$\mathbf{x}^s(k+j|k) = \mathbf{x}^s(k) + \mathbf{D}^0 \Delta \mathbf{u}(k|k) + \dots + \mathbf{D}^0 \Delta \mathbf{u}(k+j-1|k) \quad (40)$$

$$\begin{aligned} \mathbf{x}^d(k+j|k) &= \mathbf{F}^j \mathbf{x}^d(k) + \mathbf{F}^{j-1} \mathbf{D}^d \mathbf{F} \mathbf{N} \Delta \mathbf{u}(k|k) + \mathbf{F}^{j-2} \mathbf{D}^d \mathbf{F} \mathbf{N} \Delta \mathbf{u}(k+1|k) \\ &+ \dots + \mathbf{D}^d \mathbf{F} \mathbf{N} \Delta \mathbf{u}(k+m-1|k) \end{aligned} \quad (41)$$

Aplicando a Equação (39) para os instantes dentro do horizonte de controle é possível obter a seguinte expressão:

$$\bar{\mathbf{x}}^s = \bar{\mathbf{I}} \mathbf{x}^s(k) + \mathbf{D}_m^0 \Delta \mathbf{u}(k) \quad (42)$$

Em que:

$$\bar{\mathbf{x}}^s = \begin{bmatrix} \mathbf{x}^s(k+1|k) \\ \vdots \\ \mathbf{x}^s(k+m|k) \end{bmatrix}, \bar{\mathbf{x}}^s \in \mathbb{R}^{m \times ny} \quad (43)$$

$$\bar{\mathbf{I}} = \begin{bmatrix} \mathbf{I}_{ny} \\ \vdots \\ \mathbf{I}_{ny} \end{bmatrix}, \bar{\mathbf{I}} \in \mathbb{R}^{m \times ny \times ny} \quad (44)$$

$$\mathbf{D}_m^0 = \begin{bmatrix} \mathbf{D}^0 & & 0 \\ \vdots & \ddots & \\ \mathbf{D}^0 & \dots & \mathbf{D}^0 \end{bmatrix}, \mathbf{D}_m^0 \in \mathbb{R}^{m \times ny \times m \times ny} \quad (45)$$

$$\Delta \mathbf{u}(k) = \begin{bmatrix} \Delta \mathbf{u}(k|k) \\ \vdots \\ \Delta \mathbf{u}(k+m-1|k) \end{bmatrix}, \Delta \mathbf{u}(k) \in \mathbb{R}^{m \times nu} \quad (46)$$

De modo análogo, aplicando as mesmas expressões para a Equação (41) dentro do horizonte de controle:

$$\begin{bmatrix} \mathbf{x}^d(k+1|k) \\ \mathbf{x}^d(k+2|k) \\ \vdots \\ \mathbf{x}^d(k+m|k) \end{bmatrix} = \begin{bmatrix} \mathbf{F} \\ \mathbf{F}^2 \\ \vdots \\ \mathbf{F}^m \end{bmatrix} \mathbf{x}^d(k) + \quad (47)$$

$$+ \begin{bmatrix} \mathbf{I} & 0 & \cdots & 0 \\ \mathbf{F}^2 & \mathbf{I} & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{F}^{m-1} & \mathbf{F}^{m-2} & \cdots & \mathbf{I} \end{bmatrix} \begin{bmatrix} \mathbf{D}^d \mathbf{N} & 0 & \cdots & 0 \\ 0 & \mathbf{D}^d \mathbf{N} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{D}^d \mathbf{N} \end{bmatrix} \Delta \mathbf{u}(k)$$

$$\bar{\mathbf{x}}^d = \mathbf{F}_x \mathbf{x}^d(k) + \mathbf{F}_u \Delta \mathbf{u}(k) \quad (48)$$

Usando as variáveis definidas acima, é possível representar a função objetivo da Equação (31) como:

$$\min_{\Delta \mathbf{u}(k)} J(k) = \Delta \mathbf{u}(k)^T \mathbf{H} \Delta \mathbf{u}(k) + 2\mathbf{c}_f \Delta \mathbf{u}(k) + \mathbf{c} \quad (49)$$

Em que:

$$\mathbf{H} = (\mathbf{D}_m^0 + \Psi_1 \mathbf{F}_u)^T \mathbf{Q}_1 (\mathbf{D}_m^0 + \Psi_1 \mathbf{F}_u) + \mathbf{F}_u^T \mathbf{Q}_2 \mathbf{F}_u + \mathbf{R}_1 \quad (50)$$

$$\mathbf{c}_f = (\mathbf{D}_m^0 + \Psi_1 \mathbf{F}_u)^T \mathbf{Q}_1 (\bar{\mathbf{e}}^s(k) + \Psi_1 \mathbf{F}_x \mathbf{x}^d(k)) + \mathbf{F}_u^T \mathbf{Q}_2 (\mathbf{F}_x \mathbf{x}^d(k)) \quad (51)$$

$$\begin{aligned} \mathbf{c} = & \mathbf{e}(k)^T \mathbf{Q} \mathbf{e}(k) + (\bar{\mathbf{e}}^s(k) + \Psi_1 \mathbf{F}_x \mathbf{x}^d(k)) \mathbf{Q}_1 (\bar{\mathbf{e}}^s(k) + \Psi_1 \mathbf{F}_x \mathbf{x}^d(k)) \\ & + (\mathbf{F}_x \mathbf{x}^d(k))^T \mathbf{Q}_2 (\mathbf{F}_x \mathbf{x}^d(k)) \end{aligned} \quad (52)$$

$$\mathbf{Q}_1 = \overbrace{[\mathbf{Q} \cdots \mathbf{Q}]}^m \quad (53)$$

$$\mathbf{Q}_2 = \overbrace{[0 \cdots 0 \cdots \bar{\mathbf{Q}}]}^m \quad (54)$$

$$\mathbf{R}_1 = \overbrace{[\mathbf{R} \cdots \mathbf{R}]}^m \quad (55)$$

$$\Psi_1 = \overbrace{[\Psi \cdots \Psi]}^m \quad (56)$$

$$\mathbf{e}^s(k) = \mathbf{x}^s(k) - \mathbf{y}^{sp} \quad (57)$$

Em que  $\mathbf{e}^s(k)$  é definido como o erro entre o vetor  $\mathbf{x}^s(k)$  e  $\mathbf{y}^{sp}(k)$ , que representa o vetor com os valores de *setpoint* a ser alcançado. Usando a

Equação (40) é possível então reescrever a restrição apresentada na Equação (34):

$$\mathbf{e}^s(k) + \tilde{\mathbf{D}}^0 \Delta \mathbf{u}(k) = 0 \quad (58)$$

Para a qual  $\tilde{\mathbf{D}}^0 = \overbrace{[\mathbf{D}^0 \cdots \mathbf{D}^0]}^m$ . Finalmente, o problema de otimização a ser resolvido para o IHMPC, estável para sistemas com modelos contendo polos estáveis, pode ser formulado como a Equação (49), sujeito aos modelos de predição, representados pelas Equações (23) e (24), à restrição da Equação (58) e a restrição a seguir:

$$\Delta \mathbf{u}(k+j) \in \mathbf{U}, j \geq 0$$

$$\mathbf{U} = \left\{ \Delta \mathbf{u}(k+j) \left| \begin{array}{l} -\Delta \mathbf{u}^{\max} \leq \Delta \mathbf{u}(k+j) \leq \Delta \mathbf{u}^{\max} \\ \Delta \mathbf{u}(k+j) = 0, j \geq m \\ \mathbf{u}^{\min} \leq \mathbf{u}(k-1) + \sum_{i=0}^j \Delta \mathbf{u}(k+i) \leq \mathbf{u}^{\max}, j = 0, \dots, m-1 \end{array} \right. \right\} \quad (59)$$

Em contrapartida, este controlador quando implementado na prática acaba tornando-se com frequência inviável, devido ao conflito entre as restrições representadas pelas Equações (58) e (59). Tal fato ocorre, por exemplo, em situações nas quais o controlador é submetido a elevadas variações nos *setpoints* ou, quando o sistema sofre perturbações de amplitudes significativas (RODRIGUES; ODLOAK, 2003).

### 3.3 Controlador IHMPC com variáveis de folga

Com o intuito de produzir um IHMPC com maior faixa de viabilidade e implementável na prática, o trabalho de Rodrigues e Odloak (2003) propôs a inserção de uma variável de folga na função objetivo. A ideia consiste em fornecer um relaxamento na solução da restrição de igualdade da Equação (58). Dessa forma, partindo da Equação (31) e inserindo a variável de folga, a função objetivo a ser otimizada torna-se:

$$\begin{aligned} \min_{\Delta \mathbf{u}(k), \delta(k)} J(k) = & \sum_{j=1}^{\infty} (\mathbf{e}(k+j|k) - \delta(k))^T \mathbf{Q} (\mathbf{e}(k+j|k) - \delta(k)) \\ & + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) + \delta^T(k) \mathbf{S} \delta(k) \end{aligned} \quad (60)$$

Em que  $\mathbf{e}(k+j|k) = \mathbf{y}(k+j|k) - \mathbf{y}^{sp}$  é definido como o erro entre o vetor  $\mathbf{y}(k+j|k)$ , com a predição das variáveis de saída levando em conta os efeitos das ações de controle futuras ( $\mathbf{y}(k+j|k)$ ) e o vetor com os valores de *setpoint* a ser alcançado.  $\delta(k) \in \mathbb{R}^{n_y}$  é um vetor de variáveis de folga, determinado para cada variável controlada e  $\mathbf{S} \in \mathbb{R}^{n_y \times n_y}$  é uma matriz definida positiva selecionada de modo que o controlador tenda a zerar as folgas ou pelo menos minimizá-las (ODLOAK, 2004; QIN; BADGWELL, 2003).

Com base no mesmo procedimento empregado para encontrar a Equação (32) é possível obter a Equação (61).

$$\begin{aligned} \min_{\Delta \mathbf{u}(k), \delta(k)} J(k) = & \sum_{j=1}^m (\mathbf{e}(k+j|k) - \delta(k))^T \mathbf{Q} (\mathbf{e}(k+j|k) - \delta(k)) \\ & + \sum_{j=m+1}^{\infty} (\mathbf{e}(k+j|k) - \delta(k))^T \mathbf{Q} (\mathbf{e}(k+j|k) - \delta(k)) \\ & + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) + \delta^T(k) \mathbf{S} \delta(k) \end{aligned} \quad (61)$$

Assim como na seção anterior, o segundo termo do lado direito da Equação (61) pode ser desenvolvido e reescrito conforme a seguinte equação:

$$\begin{aligned} & \sum_{j=m+1}^{\infty} (\mathbf{e}(k+j|k) - \delta(k))^T \mathbf{Q} (\mathbf{e}(k+j|k) - \delta(k)) = \\ & \sum_{j=1}^{\infty} (\mathbf{x}^s(k+m|k) - \delta(k) - \mathbf{y}^{sp} + \Psi \mathbf{F}^j \mathbf{x}^d(k+m|k))^T \mathbf{Q} \\ & \sum_{j=1}^{\infty} (\mathbf{x}^s(k+m|k) - \delta(k) - \mathbf{y}^{sp} + \Psi \mathbf{F}^j \mathbf{x}^d(k+m|k)) \end{aligned} \quad (62)$$

De modo análogo com o caso sem a variável desvio, o termo  $\mathbf{x}^s(k+m|k) - \delta(k) - \mathbf{y}^{sp}$ , da soma infinita, não depende do índice  $j$  e deve ser igualado a zero para manter o objetivo de controle limitado, impedindo que a função objetivo cresça indefinidamente. Assim, torna-se necessário incluir a seguinte restrição no problema de otimização, garantindo sempre solução viável:

$$\mathbf{x}^s(k+m|k) - \boldsymbol{\delta}(k) - \mathbf{y}^{sp} = 0 \quad (63)$$

Com base nesta condição, a Equação (62) torna-se:

$$\begin{aligned} \sum_{j=m+1}^{\infty} (\mathbf{e}(k+j|k) - \boldsymbol{\delta}(k))^T \mathbf{Q} (\mathbf{e}(k+j|k) - \boldsymbol{\delta}(k)) = \\ \sum_{j=1}^{\infty} (\boldsymbol{\Psi} \mathbf{F}^j \mathbf{x}^d(k+m|k))^T \mathbf{Q} (\boldsymbol{\Psi} \mathbf{F}^j \mathbf{x}^d(k+m|k)) = \mathbf{x}^d(k+m|k)^T \bar{\mathbf{Q}} \mathbf{x}^d(k+m|k) \end{aligned} \quad (64)$$

Em que  $\bar{\mathbf{Q}} \in \mathbb{R}^{nd \times nd}$  é obtido novamente resolvendo a Equação (37). Portanto, a função objetivo da Equação (60) pode ser reescrita da seguinte forma:

$$\begin{aligned} \min_{\Delta \mathbf{u}(k), \boldsymbol{\delta}(k)} J(k) = \sum_{j=1}^m (\mathbf{e}(k+j|k) - \boldsymbol{\delta}(k))^T \mathbf{Q} (\mathbf{e}(k+j|k) - \boldsymbol{\delta}(k)) \\ + \mathbf{x}^d(k+m|k)^T \bar{\mathbf{Q}} \mathbf{x}^d(k+m|k) + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) + \boldsymbol{\delta}^T(k) \mathbf{S} \boldsymbol{\delta}(k) \end{aligned} \quad (65)$$

Tomando o mesmo raciocínio realizado na seção anterior é possível encontrar uma função objetivo de forma mais compacta, resultando na seguinte expressão quadrática:

$$\min_{\Delta \mathbf{u}(k), \boldsymbol{\delta}(k)} J(k) = \begin{bmatrix} \Delta \mathbf{u}(k)^T & \boldsymbol{\delta}(k)^T \end{bmatrix} \mathbf{H} \begin{bmatrix} \Delta \mathbf{u}(k) \\ \boldsymbol{\delta}(k) \end{bmatrix} + 2\mathbf{c}_f \begin{bmatrix} \Delta \mathbf{u}(k) \\ \boldsymbol{\delta}(k) \end{bmatrix} + \mathbf{c} \quad (66)$$

Em que:

$$\mathbf{H} = \begin{bmatrix} (\mathbf{D}_m^0 + \boldsymbol{\Psi}_1 \mathbf{F}_u)^T \mathbf{Q}_1 (\mathbf{D}_m^0 + \boldsymbol{\Psi}_1 \mathbf{F}_u) + \mathbf{F}_u^T \mathbf{Q}_2 \mathbf{F}_u + \mathbf{R}_1 & -(\mathbf{D}_m^0 + \boldsymbol{\Psi}_1 \mathbf{F}_u)^T \mathbf{Q}_1 \bar{\mathbf{I}} \\ -\bar{\mathbf{I}} \mathbf{Q}_1 (\mathbf{D}_m^0 + \boldsymbol{\Psi}_1 \mathbf{F}_u) & \mathbf{S} \bar{\mathbf{I}}^T \mathbf{Q}_1 \bar{\mathbf{I}} + \mathbf{Q} \end{bmatrix} \quad (67)$$

$$\mathbf{c}_f = \begin{bmatrix} (\mathbf{D}_m^0 + \boldsymbol{\Psi}_1 \mathbf{F}_u)^T \mathbf{Q}_1 (\bar{\mathbf{I}} \mathbf{e}^s(k) + \boldsymbol{\Psi}_1 \mathbf{F}_x \mathbf{x}^d(k)) + \mathbf{F}_u^T \mathbf{Q}_2 (\mathbf{F}_x \mathbf{x}^d(k)) \\ -\bar{\mathbf{I}} \mathbf{Q}_1 (\bar{\mathbf{I}} \mathbf{e}^s(k) + \boldsymbol{\Psi}_1 \mathbf{F}_x \mathbf{x}^d(k)) - \mathbf{Q} \mathbf{e}(k) \end{bmatrix} \quad (68)$$

$$\begin{aligned} \mathbf{c} = \mathbf{e}(k)^T \mathbf{Q} \mathbf{e}(k) + (\bar{\mathbf{I}} \mathbf{e}^s(k) + \boldsymbol{\Psi}_1 \mathbf{F}_x \mathbf{x}^d(k))^T \mathbf{Q}_1 (\bar{\mathbf{I}} \mathbf{e}^s(k) + \boldsymbol{\Psi}_1 \mathbf{F}_x \mathbf{x}^d(k)) \\ + (\mathbf{F}_x \mathbf{x}^d(k))^T \mathbf{Q}_2 (\mathbf{F}_x \mathbf{x}^d(k)) \end{aligned} \quad (69)$$

Sujeito à Equação (59) e a equação a seguir, obtida usando a Equação (23), do modelo.

$$\mathbf{x}^s(k) - \mathbf{y}^{sp} + \tilde{\mathbf{D}}^0 \Delta \mathbf{u}(k) - \boldsymbol{\delta}(k) = 0 \quad (70)$$

Com um modelo adequado, a função objetivo apresentada nesta seção consegue resolver os problemas de inviabilidade apontados anteriormente

(CARRAPIÇO; ODLOAK, 2005). Na maioria de suas aplicações, este elemento é um modelo linear, válido apenas para uma estreita faixa operacional. Entretanto, como a maioria dos processos são não-lineares e o sistema pode operar em diferentes condições operacionais, a implementação deste controlador pode ficar limitada a uma pequena região de operação, o que pode torná-los insuficientes para garantir os objetivos de controle propostos (ADETOLA; GUAY, 2009; DE OLIVEIRA; DE CARVALHO; ALVAREZ, 2019; NANDOLA; BHARTIYA, 2008).

### **3.4 Estratégia de adaptação**

Uma forma atraente de solucionar as limitações do modelo linear é considerar extensões adaptativas do controlador MPC, para as quais os parâmetros do modelo de previsão são atualizados em virtude das novas condições operacionais do processo (ADETOLA; GUAY, 2009). O processo de linearização apresentado neste artigo é baseado no desenvolvimento da função não linear em uma série de Taylor em torno do ponto de operação. Um sistema não linear, descrito a partir dos princípios de conservação (massa, energia e momento) pode ser apresentado conforme as Equações (71) e (72) (OGATA, 2010; SEBORG; THOMAS F. EDGAR, 2011).

$$\frac{dx}{dt} = f(x, u) \quad (71)$$

$$y = h(x) \quad (72)$$

Em que  $f$  é uma função não linear que descreve a dinâmica do estado do sistema e  $h$  é uma função não linear que descreve a saída do processo. A linearização é sempre realizada em torno de um ponto de referência e apenas o termo linear é retido na equação. Normalmente a condição de estado estacionário  $(\bar{y}, \bar{u}, \bar{x})$  é utilizada como ponto de referência (SEBORG; THOMAS F. EDGAR, 2011) .

$$\frac{dx}{dt} \approx f(\bar{x}, \bar{u}) + \left. \frac{\partial f}{\partial x} \right|_{\bar{x}, \bar{u}} (x - \bar{x}) + \left. \frac{\partial f}{\partial u} \right|_{\bar{x}, \bar{u}} (u - \bar{u}) \quad (73)$$

$$y \approx h(\bar{x}) + \left. \frac{\partial h}{\partial x} \right|_{\bar{x}} (x - \bar{x}) \quad (74)$$

Por definição, a condição de estado estacionário corresponde a  $f(\bar{x}, \bar{u}) = 0$  e  $h(\bar{x}) = 0$ . As equações linearizadas podem ser transformadas em funções de transferência, das quais serão extraídos os valores dos polos e realizadas as expansões em frações parciais, que por sua vez, permitem a obtenção dos parâmetros do modelo do IHMPC. Ao realizar esta transformação, deve-se considerar as variáveis como variáveis desvio, de modo que  $x' = x - \bar{x}$ ,  $y' = y - \bar{y}$  e  $u' = u - \bar{u}$  (OGATA, 2010; OGUNNAIKE; RAY, 1994).

$$\frac{dx}{dt} = ax' + bu' \quad (75)$$

$$y = cx' \quad (76)$$

As derivadas parciais foram substituídas pelos termos  $a$ ,  $b$  e  $c$ . Um modelo em função de transferência correspondente às Eq. (75) e (76) pode ser obtido pelo procedimento usual, conforme a Equação (77) para um modelo com uma única entrada e uma única saída (SISO, do inglês *Single Input Single Output*) (OGUNNAIKE; RAY, 1994).

$$y'(s) = \left[ \frac{c(x')b(x', u')}{s - a(x', u')} \right] u'(s) \quad (77)$$

Devido à condição de desprezo dos termos de ordem elevada da expansão em série de Taylor, a precisão do modelo linearizado está ligada à proximidade das variáveis em relação a condição de operação utilizada. Contudo, se as condições do processo variam muito e se afastam do estado estacionário em torno do qual o modelo foi linearizado, a linearização não se torna adequada para explicar fielmente o comportamento do processo não linear (OGATA, 2010; OGUNNAIKE; RAY, 1994).

Dessa forma, a implementação de um controlador adaptativo procura aprimorar o desempenho do modelo linearizado a partir das equações não lineares do sistema. Através da percepção das condições operacionais atuais, o controlador realiza uma adaptação sistemática e adequa novas aproximações lineares para o controlador a cada instante de tempo (OGUNNAIKE; RAY, 1994).

A Figura 2 representa um esquema da estrutura proposta para implementação do IHMPC.

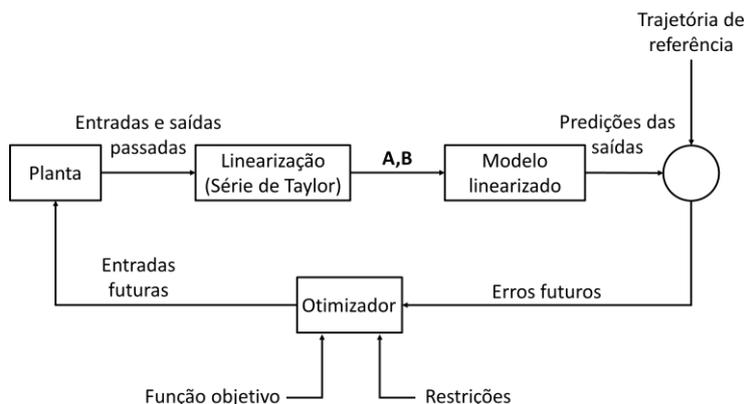


Figura 2 - Estratégia de implementação do IHMPC Adaptativo. Fonte: Adaptado de Camacho; Bordons, 2007.

É importante ressaltar que, embora a representação nominal deste controlador tenha como característica a garantia de estabilidade, um controlador com a proposta de adaptação *online* das matrizes  $A$  e  $B$  do sistema não possui esta mesma garantia (A. RODRIGUES; ODLOAK, 2003).

Outra característica desejada em aplicações de controladores avançados em sistemas modernos é a garantia de uma operação atraente do ponto de vista econômico, ou seja, a busca pela maximização de lucros e/ou minimização de custos de operação (SANTANDER; ELKAMEL; BUDMAN, 2016). Na prática, o objetivo econômico nos controladores MPC é alcançado pelo projeto de sistemas de controle por meio de uma estrutura hierárquica ordenada em várias camadas. Neste arranjo, cada nível opera em uma escala de tempo distinta. Normalmente, essas camadas são dispostas na seguinte organização: planejamento da produção (semanas), programação da produção (dias), otimização operacional (horas), controle supervisorio/preditivo (minutos) e controle regulatório (segundos) (DUTRA, 2012; FERRAMOSCA; GONZÁLEZ; LIMON, 2017; SKOGESTAD, 2000).

A estrutura de controle hierárquica classificada conforme a escala de tempo é apresentada na Figura 3. A camada de controle regulatório, a base da estrutura, faz referência ao controle do inventário do processo (balanços de massa, energia e quantidade de movimento) e envolve as vazões, pressões, níveis e temperatura dos sistemas, de modo a lidar com as perturbações de alta

frequência no desafio de manter a planta estável. A camada supervisória, em contrapartida, atua no controle da taxa de produção e qualidade do produto. Avançando no sentido ascendente, a camada de otimização operacional representa aquela na qual ocorrem os cálculos dos valores desejados para a camada supervisória. As camadas superiores, que trabalham em frequência de dias e meses, consideram aspectos globais e operacionais do sistema e informações do mercado (ALVAREZ, 2012; DUTRA, 2012; FERRAMOSCA; GONZÁLEZ; LIMON, 2017).



Figura 3 - Estrutura hierárquica de controle conforme a escala de tempo. Fonte: Skogestad (2000), modificado pelo autor.

### 3.5 Integração estável MPC e RTO

A otimização do processo em tempo real (RTO) representa a camada que lida com um objetivo econômico. A sua implementação baseia-se na análise da operação do sistema por meio dos modelos não lineares dos processos em estado estacionário, juntamente com a reconciliação/estimativas de dados e parâmetros (DE SOUZA; ODLOAK; ZANIN, 2010). Seu papel é otimizar as condições operacionais econômicas ótimas do processo e atualizar os *setpoints* para os MPCs locais das camadas inferiores. O controlador MPC, por sua vez, representa uma camada baseada em modelos lineares dinâmicos. A tarefa destes controladores consiste em receber os alvos enviados pela RTO e realizar

uma otimização, movendo as condições da planta para o ponto de operação mais lucrativo (ALVAREZ; ODLOAK, 2012; GONZÁLEZ; ODLOAK, 2009).

Os modelos usados em ambas camadas são frequentemente diferentes e pode haver incompatibilidade entre os estados estacionários. Outro fator que necessita de atenção nessas aplicações está ligado à diferença entre as frequências de execução de ambas as camadas, já que a RTO trabalha em escalas de horas e o MPC em minutos ou segundos. Estes agravantes podem ocasionar situações em que a presença de perturbações ( $\mathbf{d}(k)$ ) no processo altere o ponto ótimo econômico de operação e o sistema seja executado em condições distintas até a próxima atualização feita pela RTO (ALVAREZ; ODLOAK, 2012; DE SOUZA; ODLOAK; ZANIN, 2010; SANTANDER; ELKAMEL; BUDMAN, 2016).

Em muitos casos, a solução para esse problema recai na formulação de uma RTO dinâmica ou um MPC com um alvo econômico, que realiza uma junção entre o controle dinâmico e a otimização de objetivos econômicos. Entretanto, estas abordagens podem apresentar problemas relacionados principalmente à estabilidade e carga computacional, não se apresentando como a mais adequada em algumas aplicações (DE PRADA *et al.*, 2017).

Uma solução atrativa para esse problema é a adição de um novo nível de otimização entre a RTO e o MPC, denominado cálculo de alvos (TC, do inglês *Target Calculation*), como apresentado na Figura 4 (ALVAREZ, 2012). Essa camada intermediária, que opera na mesma frequência que o controlador, é formulada como uma programação quadrática com o objetivo de calcular alvos alcançáveis para a camada inferior (MPC). Um MPC de horizonte infinito com estabilidade garantida e restrições adicionais força a viabilidade e a convergência da camada TC. Esse controlador apresenta particularidades que o tornam úteis em uma aplicação com RTO. Dentre essas características, é possível citar: controle por zona, a abordagem de *setpoints* como variáveis de otimização do controlador, a adição de variáveis de folgas para evitar que a função objetivo do controlador se torne ilimitada e o ajuste do controlador para receber os alvos das variáveis manipuladas (ALVAREZ, 2012; ALVAREZ; ODLOAK, 2010).

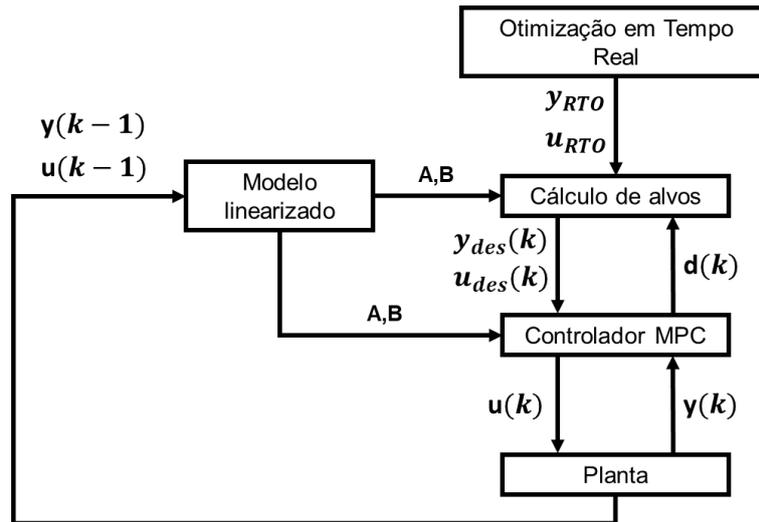


Figura 4 - Interação RTO e MPC Adaptativo. Adaptado de Alvarez e Odloak (2012).

### 3.5.1 Integração estável de MPC e RTO em três camadas

A solução da RTO fornece valores ótimos para as entradas ( $\mathbf{u}_{RTO}$ ) e saídas ( $\mathbf{y}_{RTO}$ ) de um sistema com  $nu$  entradas e  $ny$  saídas. No instante de tempo  $k$ , a camada de cálculo de alvos resolve o problema de otimização apresentado na Equação (78) (ALVAREZ; ODLOAK, 2010). O controlador usa como modelo de predição uma formulação em espaço de estado adequado para implementação de um MPC livre de *offset* (ODLOAK, 2004).

$$\min_{\mathbf{y}_{des}(k), \mathbf{u}_{des}(k), \boldsymbol{\varepsilon}(k)} J_{TC}(k) = (\mathbf{y}_{des}(k) - \mathbf{y}_{RTO})^T \mathbf{C}_y (\mathbf{y}_{des}(k) - \mathbf{y}_{RTO}) + (\mathbf{u}_{des}(k) - \mathbf{u}_{RTO})^T \mathbf{C}_u (\mathbf{u}_{des}(k) - \mathbf{u}_{RTO}) + \boldsymbol{\varepsilon}^T(k) \mathbf{C}_\varepsilon \boldsymbol{\varepsilon}(k) \quad (78)$$

Sujeito a:

$$\mathbf{y}_{des}(k) - \mathbf{y}(\infty | k) = \mathbf{D}^0 (\mathbf{u}_{des}(k) - \mathbf{u}(k-1)) \quad (79)$$

$$\mathbf{y}_{\min} + \boldsymbol{\varepsilon}(k) \leq \mathbf{y}_{des}(k) \leq \mathbf{y}_{\max} + \boldsymbol{\varepsilon}(k) \quad (80)$$

$$-m\Delta \mathbf{u}_{\max} \leq \mathbf{u}_{des}(k) - \mathbf{u}(k-1) \leq m\Delta \mathbf{u}_{\max} \quad (81)$$

$$\mathbf{u}_{\min} \leq \mathbf{u}_{des}(k) \leq \mathbf{u}_{\max} \quad (82)$$

As variáveis  $\mathbf{C}_y$ ,  $\mathbf{C}_u$  e  $\mathbf{C}_\varepsilon$  são as matrizes positivas definidas que contêm os pesos na otimização das variáveis controladas, nas entradas e das variáveis de

folga, respectivamente. A Equação (79) representa o modelo em regime permanente e relaciona as saídas previstas de um estado estacionário em um tempo infinito e a ação de controle aplicada ao processo no tempo anterior  $\{\mathbf{y}(\infty|k), \mathbf{u}(k-1)\}$  com o estado estacionário desejado calculado pela camada TC  $\{\mathbf{y}_{des}(k), \mathbf{u}_{des}(k)\}$ .  $\boldsymbol{\varepsilon}(k)$  é uma variável de folga usada para suavizar as restrições de limites associadas à variável  $\mathbf{y}_{des}(k)$  permitindo que essa variável alcance valores fora da zona de controle da saída (ALVAREZ; ODLOAK, 2010).

É importante ressaltar que nem todas as variáveis de entrada ou de saída são objetivos de otimização nessa etapa. Uma suposição para definir as variáveis que possuem metas na camada TC é dada pela Equação (83) (ALVAREZ, 2012).

$$ny_t + nu_t \leq nu \quad (83)$$

$ny_t$  e  $nu_t$  são as variáveis de saída e de entrada otimizadas, respectivamente. O número de graus de liberdade disponíveis no sistema é  $nu$  (ALVAREZ; ODLOAK, 2010).

Os valores ótimos desejados  $\{\mathbf{y}_{des}(k), \mathbf{u}_{des}(k)\}$  são enviados para a camada dinâmica, baseada no controlador MPC de horizonte infinito. Esse controlador resolve o problema de otimização dado pela Equação (84) e suas restrições (85) – (91) (GONZÁLEZ; ODLOAK, 2009).

$$\begin{aligned} \min_{\Delta \mathbf{u}(k), \mathbf{y}_{sp}(k), \boldsymbol{\delta}_y(k)} J_{MPC}(k) = & \\ \sum_{j=0}^{\infty} (\mathbf{y}(k+j|k) - \mathbf{y}_{sp}(k) - \boldsymbol{\delta}_y(k))^T \mathbf{Q}_y (\mathbf{y}(k+j|k) - \mathbf{y}_{sp}(k) - \boldsymbol{\delta}_y(k)) & \\ + \sum_{j=0}^{\infty} (\mathbf{u}(k+j|k) - \mathbf{u}_{des}(k))^T \mathbf{Q}_u (\mathbf{u}(k+j|k) - \mathbf{u}_{des}(k)) & \\ + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) + \boldsymbol{\delta}_y^T(k) \mathbf{S}_y \boldsymbol{\delta}_y(k) & \end{aligned} \quad (84)$$

Sujeito a:

$$-\Delta \mathbf{u}_{\max} \leq \Delta \mathbf{u}(k+j|k) \leq \Delta \mathbf{u}_{\max}, j=0, \dots, m-1 \quad (85)$$

$$\mathbf{u}_{\min} \leq \mathbf{u}(k+j|k) \leq \mathbf{u}_{\max}, j=0, \dots, m-1 \quad (86)$$

$$\mathbf{y}(\infty|k) + \tilde{\mathbf{D}}^0 \Delta \mathbf{u}(k) - \mathbf{y}_{sp}(k) - \boldsymbol{\delta}_y(k) = 0 \quad (87)$$

$$\mathbf{y}_{sp}(k) = \mathbf{y}_{des}(k) - \boldsymbol{\delta}_y(k) \quad (88)$$

$$\boldsymbol{\delta}_y(k) = \boldsymbol{\varepsilon}(k) \quad (89)$$

$$\mathbf{y}_{\min} \leq \mathbf{y}_{sp}(k) \leq \mathbf{y}_{\max} \quad (90)$$

$$\mathbf{u}(k-1) + \tilde{\mathbf{I}}\Delta\mathbf{u}(k) - \mathbf{u}_{des}(k) = 0 \quad (91)$$

Nessa camada, as variáveis  $\mathbf{Q}_y$ ,  $\mathbf{Q}_u$ ,  $\boldsymbol{\delta}_y$  e  $\mathbf{R}$  representam as matrizes de dimensões apropriadas com os pesos na otimização das variáveis controladas, manipuladas, do esforço de controle e das variáveis de folga, respectivamente e a matriz  $\tilde{\mathbf{I}}$  é definida como (ALVAREZ, 2012):

$$\tilde{\mathbf{I}} = \overbrace{[\mathbf{I}_{nu} \cdots \mathbf{I}_{nu}]}^m \quad (92)$$

### 3.6 Comentários finais

De acordo com o apresentado ao longo deste capítulo, os controladores MPC apresentam formulação em que o uso de modelo linear os torna mais tratáveis do ponto de vista de solução do já complexo problema de otimização integrado de projeto e da estrutura de controle. Contudo, como a maioria dos processos reais são não lineares e podem operar em condições distintas daquelas utilizadas para a obtenção do modelo linear, este trabalho visa propor uma extensão adaptativa para atualização dos modelos lineares do controlador IHMPC com base nos parâmetros e condições do processo no problema de otimização simultânea. Além disso, a proposta de adaptação também foi avaliada em um contexto de otimização simultânea em que as camadas de RTO e do controlador MPC foram integradas.

Desse modo, o próximo capítulo apresenta a metodologia para o projeto integrado proposto neste trabalho, bem como as estratégias utilizadas para a solução deste problema de otimização.

## 4 METODOLOGIA

A metodologia proposta sobre projeto simultâneo de processos e do sistema de controle é apresentada neste capítulo. A proposta pressupõe que a síntese e o fluxograma do processo já se encontram disponíveis, com correntes e equipamentos previamente definidos, porém não dimensionados. Assume-se também que o sistema de controle, ou seja, as variáveis controladas e manipuladas, as malhas de controle e o tipo de controlador são definidos previamente. No que diz respeito às variáveis manipuladas e controladas, o pareamento pode recair segundo a aplicação de métodos heurísticos ou usando procedimentos já conhecidos previamente na literatura (VAN DE WAL; DE JAGER, 2001). Com relação ao controlador, será adotado o controlador preditivo com horizonte infinito e modelo de espaço de estados na forma incremental.

Partindo da premissa de que a estratégia, estrutura de controle e o controlador estão definidos e assumindo que um modelo do processo está disponível, o problema simultâneo de projeto de processos e de seu sistema de controle pode ser formulado. Sua solução busca encontrar as dimensões ótimas dos equipamentos, as condições operacionais ótimas (incluindo *setpoints* para as variáveis controladas) e os parâmetros de sintonia do controlador que atendam concomitantemente aos critérios econômicos e dinâmicos. Para isso, o problema é sujeito a um conjunto de restrições que asseguram o comportamento dinâmico desejado e satisfazem as especificações do sistema.

### **4.1 Formulação geral do problema SPDC**

O problema SPDC foi formulado como um problema de otimização matemática que busca atender simultaneamente a dois tipos de objetivos: econômico e dinâmico. Mais precisamente, é declarado como um problema de Programação Não Linear (NLP) sujeito às restrições do processo (modelo matemático dinâmico e em estado estacionário), equações constitutivas, equações do modelo do controlador e outras restrições específicas do processo, conforme apresentado na Figura 5.

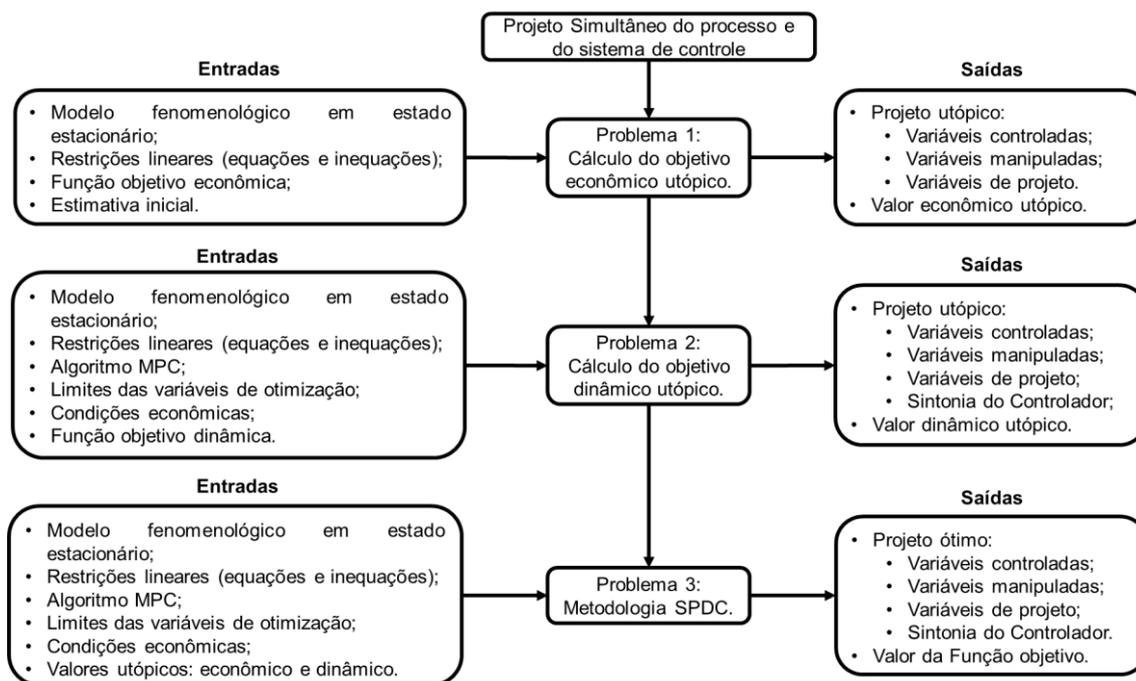


Figura 5 - Metodologia SPDC proposta.

O objetivo econômico ( $\phi_{eco}$ ) está relacionado aos métodos de dimensionamento dos equipamentos e cálculo de condições ótimas econômicas. A função econômica, representada pela Equação (93), compreende a solução de um problema de otimização que considera o modelo fenomenológico do sistema em estado estacionário como restrição, no qual o objetivo pode ser a minimização de um custo, a maximização de produção e/ou lucro ou até mesmo a maximização do retorno de investimento inicial da planta, por meio de uma função que considera o balanço entre o mínimo de investimento e o máximo de lucro. As variáveis de otimização desse problema são as dimensões ótimas dos equipamentos e as condições operacionais ótimas do processo. Os custos relacionados aos investimentos em equipamentos são obtidos por meio de correlações empíricas presentes na literatura e os custos operacionais referentes às matérias primas são considerados em períodos e anualizados para um determinado período de vida útil da planta (VEGA *et al.*, 2014b; YUAN *et al.*, 2012).

#### Problema 1:

$$\min_{\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}} \phi_{eco} = f_{eco}(\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}) \quad (93)$$

Sujeito a:

$$\mathbf{f}(\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}) = 0 \quad (94)$$

$$\mathbf{g}(\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}) < 0 \quad (95)$$

Além disso, o problema também é restrito pelas Equações (5) – (8).

O objetivo dinâmico ( $\phi_{dyn}$ ) está geralmente relacionado ao desempenho dinâmico desejado do processo operando na presença de controlador. A metodologia apresentada neste trabalho é fundamentada no objetivo de flexibilidade do processo, determinado pela capacidade do mesmo em mudar de *setpoint* de forma rápida e suave ao mesmo tempo em que garante uma operação viável, evitando a violação das restrições (SHARIFZADEH, 2013). Para isso, considerou-se uma mudança de condições de mercado, definidas pela alteração nos preços dos componentes do processo como variação no *setpoint*. Para cada variável controlada ( $y_i, i = 1, \dots, ny$ ) foi definida uma trajetória ideal ( $y_i^{ref}, i = 1, \dots, ny$ ) entre os dois valores desejados, com base nos estados estacionários da condição de mercado 1 ( $y_i^{sp}, i = 1, \dots, ny$ ) e da condição 2, respectivamente. A função objetivo dinâmica utópica (Problema 2) foi calculada por meio da soma dos erros quadráticos entre o valor da trajetória ( $y_i^{ref}(k)$ ) e o valor de cada variável controlada ( $y_i$ ) para todo o horizonte de simulação  $\theta_t$ .

### Problema 2:

$$\min_{\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}, \mathbf{v}} \phi_{dyn} = \sum_{k=1}^{\theta_t} \|\mathbf{y}^{ref}(k) - \mathbf{y}(k)\|_{\mathbf{T}}^2 \quad (96)$$

Sujeito às Equações (2) – (9).

Em que  $\theta_t$  é o horizonte de tempo em que os valores de erro são calculados,  $\mathbf{T}$  é uma matriz diagonal positiva definida com valores de pesos de rastreamento da trajetória, que são determinados com base na importância atribuída a cada variável controlada. A trajetória ideal considerada é o comportamento de um sistema de primeira ordem no tempo, conforme apresentada pelas Equações (97) e (98).

$$y_i^{ref}(k) = y_i^{sp1}, i = 1, \dots, ny \text{ e } k < \theta_t \quad (97)$$

$$y_i^{ref}(k) = y_i^{sp1} + \left( y_i^{sp2} - y_i^{p1} \right) \left( 1 - e^{-\left( k - \theta_1 \right) \Delta t / \tau_i} \right), i = 1, \dots, ny \text{ e } k \geq \theta_1 \quad (98)$$

$\theta_1$  é o horizonte de tempo em que os valores desejados das variáveis controladas são os valores para a primeira condição de mercado. As variáveis  $y^{sp1}$  e  $y^{sp2}$  são os valores desejados calculados pela otimização do Problema 1 utilizando as condições de mercado 1 e 2, respectivamente. As variáveis  $\tau_i, i = 1, \dots, ny$  representam as constantes de tempo da função trajetória da saída, definidos conforme Rivera *et al.*, (1986), em que o valor deve ser maior que 10% e menor que 90% do valor da constante de tempo da variável  $y_i, i = 1, \dots, ny$ , definida como uma fração do tempo de resposta do processo a um desvio degrau em suas variáveis manipuladas, quando este opera em malha aberta (SEBORG; THOMAS F. EDGAR, 2011).

A trajetória a ser seguida pelo controlador é apresentada conforme a Figura 6.

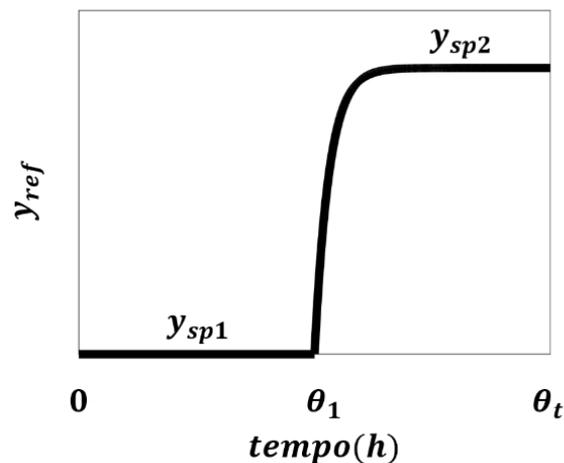


Figura 6 - Trajetória de referência: Resposta de primeira ordem entre dois *setpoints*.

### Problema 3:

$$\min_{x,y,u,p,v} \phi_{SPDC} = f(\phi_{eco}, \phi_{din}) \quad (99)$$

Sujeito às Equações (2) – (9).

O problema resultante da combinação dos objetivos econômicos e dinâmicos em inúmeros casos pode se apresentar com solução muito complexa (SHARIFZADEH, 2013).

## 4.2 Estratégias de solução do problema de otimização

A metodologia, conforme apresentada na Figura 5, inicia-se pelos cálculos dos valores utópicos para os objetivos econômicos e dinâmicos (Problemas 1 e 2). Após conhecer os valores utópicos dos respectivos objetivos, o passo seguinte consiste na formulação do problema de otimização (Problema 3). O presente trabalho avaliou duas estratégias para solucionar o problema de otimização, a saber, o método de alcance de metas e o cálculo do custo quadrático.

### 4.2.1 Alcance de metas

O método consiste em reduzir o conjunto de objetivos não lineares a um conjunto de metas. No contexto da proposta atual o conjunto  $[\phi_{eco}^{Ut}, \phi_{dyn}^{Ut}]$  representa as metas para o conjunto de objetivos  $[\phi_{eco}, \phi_{dyn}]$ . O problema de alcance de metas utiliza uma variável de folga  $\gamma$  para minimizar de modo simultâneo o conjunto de objetivos (GEMBICKI; HAIMES, 1975):

$$\min_{x,y,u,d,c} \gamma \quad (100)$$

Sujeito a:

$$\phi_{eco} - \mathbf{\Pi}_E \gamma \leq \phi_{eco}^{Ut} \quad (101)$$

$$\phi_{din} - \mathbf{\Pi}_D \gamma \leq \phi_{din}^{Ut} \quad (102)$$

Sujeito também às Equações (2) – (9).  $\mathbf{\Pi}_E$  e  $\mathbf{\Pi}_D$  são as matrizes que contêm os pesos atribuídos a cada um dos objetivos a serem otimizados, conforme a sua importância.

#### 4.2.2 Custo quadrático

A segunda alternativa abordada neste trabalho é a definição da função objetivo do problema na forma quadrática, na qual cada termo representa a busca da solução que melhor se aproxima dos valores utópicos por um problema de rastreamento dos mesmos. A formulação proposta é apresentada na Equação (103).

$$\phi_{SPDC} = \|\phi_{eco} - \phi_{eco}^{Ur}\|_{\Omega_E}^2 + \|\phi_{dyn} - \phi_{dyn}^{Ur}\|_{\Omega_D}^2 \quad (103)$$

Sujeito às Equações (2) – (9).

$\Omega_E$  e  $\Omega_D$  são as matrizes que contêm os pesos atribuídos a cada um dos objetivos a serem otimizados, conforme a sua importância.

Os pesos de cada problema de otimização são definidos conforme a importância dada no rastreamento de cada objetivo. Vale a pena ressaltar que, para o método de alcance de metas, uma importância de atingir a meta proposta para um determinado objetivo implica em valores de pesos numericamente menores, pois nesse método, um peso menor tem maior probabilidade de tornar o seu componente quase satisfeito quando ambas as metas são conflitantes e difíceis de serem alcançadas simultaneamente. Em contrapartida, os pesos para o método de custo quadrático devem ser aumentados numericamente quando um objetivo possui maior importância do que o outro. Neste trabalho, buscou-se dar a mesma importância para ambos objetivos (econômico e dinâmico), pois os mesmos foram normalizados, com o intuito de equiparar a dimensão numérica entre os seus valores (GEMBICKI; HAIMES, 1975; MARLER; ARORA, 2010).

#### **4.3 Projeto simultâneo usando IHMPC linear**

A formulação do controlador IHMPC utilizado neste trabalho requer o uso de apenas um modelo linear do processo, por meio do qual em cada instante de tempo realiza-se uma previsão das respostas futuras do sistema. Os modelos

foram ajustados a 1ª e 2ª ordem pela resposta do processo a uma variação degrau de 10% nas variáveis manipuladas.

As condições escolhidas para a identificação deste modelo foram obtidas através do projeto econômico ótimo para a primeira condição de mercado, calculadas no problema 1. Este problema foi resolvido para as 2 condições de mercado através da função *fmincon* do Matlab, com as opções padrões do algoritmo.

Nesta parte do trabalho, esses modelos foram utilizados primeiramente no problema 2 (otimização do objetivo dinâmico). Esta etapa consistiu em encontrar o vetor de parâmetros ótimos de sintonia que formam as matrizes **Q**, e **R**. Além disso, o problema também buscou encontrar os parâmetros ótimos do processo (**p**) e as variáveis referentes às condições operacionais (**y** e **u**), considerando apenas o objetivo dinâmico de minimizar o erro quadrático.

Por fim, o problema 3 (otimização simultânea) foi solucionado e buscou-se encontrar novamente os valores ótimos dos parâmetros de sintonia do controlador, juntamente com as condições operacionais do processo, considerando de maneira simultânea a otimização dos aspectos dinâmicos e econômicos, em que o problema buscou chegar o mais próximo possível dos objetivos utópicos através da formulação em custo quadrático e pelo alcance de metas.

O algoritmo utilizado na solução dos Problemas 2 e 3 foi o *direct*, também implementado no Matlab (FINKEL, 2003), juntamente com o *fgoalattain*, utilizado apenas para o Problema 3. As configurações de cada algoritmo utilizado são fornecidas de acordo com a Tabela 1.

Tabela 1 - Configurações e algoritmos de otimização usados no trabalho.

<b>Problema 1</b>		
Função <i>fmincon</i>		
Configuração	Padrão	
<b>Problema 2 e Problema 3</b>		
Função <i>direct</i>		
	<i>'maxits'</i>	1000
	<i>'maxevals'</i>	2000
	<i>'maxdeep'</i>	100
	<i>'tesflag'</i>	0
Configuração	<i>'globalmin'</i>	1e-30
	<i>'tol'</i>	0,01
	<i>'showits'</i>	1
	<i>'impcons'</i>	0
	<i>'pert'</i>	1e-6
Função <i>fgoalattain</i>		
Configuração	Padrão	

#### 4.4 Projeto simultâneo usando IHMPC adaptativo

A estratégia adaptativa consistiu em linearizar via expansão em série de Taylor o modelo não linear do processo. O modelo resultante é atualizado em cada instante de tempo, com base nas condições atuais do processo. Assim, o modelo é ajustado às novas condições de operação se houver mudanças no processo provenientes de alterações no *setpoint* ou perturbações no sistema.

O procedimento consistiu novamente em solucionar os problemas 1 e 2, encontrar os valores utópicos e com eles resolver o problema 3, encontrando simultaneamente a planta que melhor atendeu os objetivos econômico e dinâmico. As configurações utilizadas para os algoritmos *fmincon*, *direct* e *goalattainment* foram as mesmas utilizadas na seção anterior.

#### 4.5 Projeto simultâneo usando a estrutura MPC-RTO em três camadas

Nesta etapa, uma estrutura MPC-RTO em três camadas foi utilizada com o objetivo de melhorar os índices econômicos e dinâmicos do projeto simultâneo. Os resultados foram obtidos a fim de comparar diferentes estratégias para a substituição de um modelo linear obtido em uma determinada condição de operação. Para isso, foram usadas 2 diferentes abordagens para o modelo linear de predição: a adaptativa através da linearização em cada instante de tempo e uma abordagem adaptativa baseada em múltiplos modelos. A adaptação em múltiplos modelos deu-se de modo que sequência de controle enviada para a planta fosse uma combinação linear daquelas obtidas em cada um dos modelos utilizados para prever o comportamento do sistema, conforme apresentado na Equação (104).

$$\mathbf{u}(k) = \sum_{i=1}^L v_i(k) u_i(k) \quad (104)$$

Em que  $v_i(k), i=1, \dots, L$  são os pesos das ações de controle correspondentes a cada modelo  $i$  no instante de tempo  $k$ . Os pesos são todos positivos e são calculados em cada tempo de amostragem considerando a distância Euclidiana entre o valor atual da saída e o ponto onde cada modelo foi obtido (DE OLIVEIRA; DE CARVALHO; ALVAREZ, 2019). Além disso, eles devem satisfazer à seguinte restrição:

$$\sum_{i=1}^L v_i(k) = 1 \quad (105)$$

Vale a pena ressaltar que quanto maior a quantidade e mais abrangente forem os modelos disponíveis, maior a faixa operacional de validade dos mesmos e melhor a precisão do modelo ao calcular a ação de controle (DE OLIVEIRA; DE CARVALHO; ALVAREZ, 2019).

## 5 Estudo de caso

Este capítulo tem como objetivo apresentar o sistema utilizado neste trabalho como estudo de caso, a saber o reator de Williams-Otto. As equações de projeto, bem como os modelos de predição e os preços das funções de otimização em tempo real (RTO) são apresentados e detalhados ao longo da seção.

### 5.1 Estudo de caso: Reator Williams-Otto

O reator de Williams-Otto é exemplo que considera um reator de mistura perfeita (CSTR, do inglês *Continuous Stirred-Tank Reactor*) não isotérmico, no qual a concentração das espécies na saída é a mesma que no interior do reator (Figura 7). No seu interior ocorrem três reações em paralelo, conforme apresentado pelas Equações (106) – (108). O reator é alimentado por duas correntes de reagentes puros, definidas em vazão mássica ( $F_A$  e  $F_B$ ) e vazão mássica da saída do reator é composta por todos os 6 componentes envolvidos na reação (WILLIAMS; OTTO, 1960).

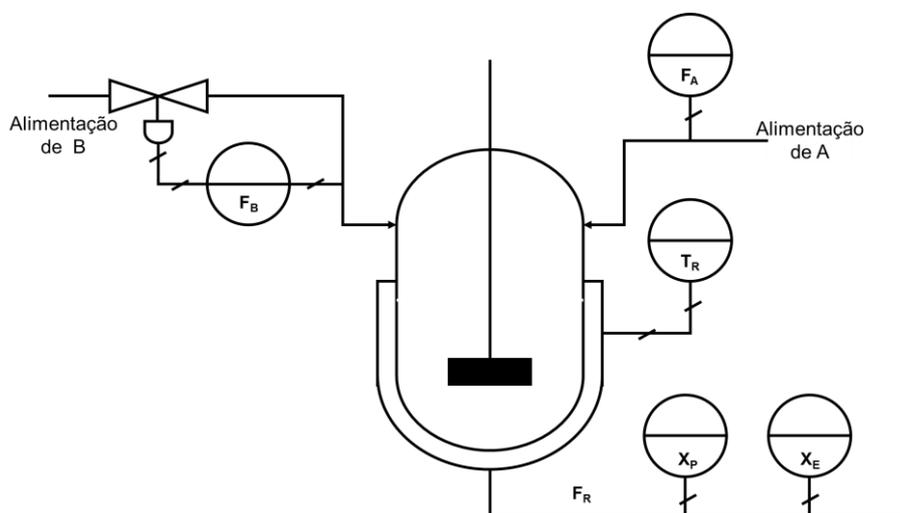


Figura 7 - Reator de Williams-Otto. Adaptado de Cubillos; Acuña; Lima (2007).





$P$  é o produto desejado,  $E$  é um subproduto com valor de venda agregado,  $C$  é um intermediário complexo, sem valor de venda e  $G$  é um material residual. Os balanços de massa no regime transiente definem os modelos que representam a variação da composição de cada componente no interior do reator (AMRIT, 2011; SANTANDER, 2015):

$$\frac{dX_A}{dt} = \frac{F_A}{W} - \frac{(F_A + F_B)}{W} X_A - \frac{\sigma_1}{W} \quad (109)$$

$$\frac{dX_B}{dt} = \frac{F_B}{W} - \frac{(F_A + F_B)}{W} X_B - \frac{\sigma_1}{W} - \frac{\sigma_2}{W} \quad (110)$$

$$\frac{dX_C}{dt} = -\frac{(F_A + F_B)}{W} X_C + \left(\frac{M_C}{M_B}\right) \frac{\sigma_1}{W} - \left(\frac{M_C}{M_B}\right) \frac{\sigma_2}{W} - \frac{\sigma_3}{W} \quad (111)$$

$$\frac{dX_E}{dt} = -\frac{(F_A + F_B)}{W} X_E + \left(\frac{M_E}{M_B}\right) \frac{\sigma_2}{W} \quad (112)$$

$$\frac{dX_G}{dt} = -\frac{(F_A + F_B)}{W} X_G + \left(\frac{M_G}{M_C}\right) \frac{\sigma_3}{W} \quad (113)$$

$$\frac{dX_P}{dt} = -\frac{(F_A + F_B)}{W} X_P + \frac{\sigma_2}{W} - \left(\frac{M_P}{M_C}\right) \frac{\sigma_3}{W} \quad (114)$$

O vetor de variáveis  $\mathbf{x} = [X_A, X_B, X_C, X_E, X_G, X_P]$  representa as frações mássicas de cada componente no interior do reator e contém os estados do sistema. A variável  $W$  representa a massa no interior do reator, considerada como a variável de parâmetro  $\mathbf{p}$ . As constantes  $M_B = 100$ ,  $M_C = 200$ ,  $M_E = 200$ ,  $M_P = 100$  e  $M_G = 300$  são respectivamente as massas moleculares dos elementos  $B$ ,  $C$ ,  $E$ ,  $P$  e  $G$ . As taxas de reações  $\sigma_1$ ,  $\sigma_2$  e  $\sigma_3$  são descritas de acordo com as Equações (115) – (117):

$$\sigma_1 = k_1 X_A X_B W \quad (115)$$

$$\sigma_2 = k_2 X_B X_C W \quad (116)$$

$$\sigma_3 = k_3 X_C X_P W \quad (117)$$

As constantes das reações  $k_1$ ,  $k_2$  e  $k_3$  são definidas pela equação de Arrhenius, conforme mostrada pelas Equações (118) – (120) e são funções da temperatura do reator  $T_R$  ( $^{\circ}\text{C}$ ).

$$k_1 = 1,6599 \times 10^6 \exp(-6666,7 / (T_R + 273,15)) \quad (118)$$

$$k_2 = 7,2117 \times 10^8 \exp(-8333,33 / (T_R + 273,15)) \quad (119)$$

$$k_3 = 2,674510^{12} \exp(-11111 / (T_R + 273,15)) \quad (120)$$

As variáveis controladas escolhidas foram  $\mathbf{y} = [X_E, X_P]$ , que estão diretamente relacionadas ao lucro obtido pela operação da planta.  $F_A$  é uma variável de perturbação medida, que permite a introdução de perturbações para avaliação da dinâmica do sistema. As variáveis manipuladas são  $\mathbf{u} = [F_B, T_R]$  e foram definidas como comumente utilizadas na literatura (AMRIT; RAWLINGS; BIEGLER, 2013).

## 5.2 Objetivo econômico: Problema 1

O problema de otimização econômico, responsável por calcular o projeto de processo correspondente ao problema 1 é definido como a maximização de uma função que calcula o retorno de investimento da planta:

$$\min_{\mathbf{x}, \mathbf{y}, \mathbf{u}, \mathbf{p}} \phi_{eco} = 100 \frac{M - SARE - U - FCP}{PIN} \quad (121)$$

Sujeito às Equações (4) – (8) e (94) – (95).

Os termos da função objetivo do Problema 1 são definidos conforme as Equações (122) – (126).

$$M = 8400(P_P F_P + P_E F_E - P_A F_A - P_B F_B) \quad (122)$$

$$SARE = 1041.6(P_P F_P + P_E F_E) \quad (123)$$

$$FCP = 60\mathbf{p} \quad (124)$$

$$U = 8400(C_2 (F_R)^{1.5}) \quad (125)$$

$$PIN = 600p \quad (126)$$

A Equação (122) representa o retorno bruto anual e é calculado pela diferença entre o lucro (relação entre a quantidade produzida e o valor de mercado dos produtos) e o custo (relação entre a quantidade necessária de reagente e os seus respectivos custos). A Equação (123), que define a parte da função destinada à contabilização dos custos relacionados às vendas, administração, taxas de pesquisa e engenharia, SARE (do inglês *Sales, Administration, Research and Engineering charges*) a Equação (124) está relacionada aos custos fixos (depreciação dos equipamentos e taxas laborais), FCP (do inglês *Fixed charges – depreciation, labor, etc.*) e a Equação (125) representa os custos relacionados às utilidades e correntes do processo U (do inglês *Utility charges*), calculado a partir das vazões da planta. Por fim, a Equação (126) quantifica o investimento inicial total da planta.  $P_p$  e  $P_E$  são os preços dos produtos,  $P_A$  e  $P_B$  os preços dos reagentes da reação, enquanto  $F_p$  e  $P_E$  as suas vazões mássicas de saída para os elementos  $P$  e  $E$ .  $C_2 = (0,01)^{1,5}$  é o preço relacionado ao custo de utilidade da operação do reator (CARDOSO, 2016).

Os valores de preços das condições de mercado utilizadas no cálculo do Problema 1 são apresentados na **Erro! Fonte de referência não encontrada..** Para condição 1, utilizada para indicar o *setpoint* inicial do reator, os valores de preços foram obtidos através do trabalho de (AMRIT, 2011). Para a segunda condição de mercado, os preços foram alterados com o intuito de obter novos valores desejados de estado estacionário para o sistema, definidos como o *setpoint* final do reator. Ambas as condições operacionais de estado estacionário são obtidas otimizando a função objetivo do problema 1 e foram usadas para traçar a trajetória ótima que o sistema necessita percorrer nos problemas dinâmico e simultâneo.

Tabela 2 - Preços dos compostos reacionais para as condições 1 e 2.

Condição de mercado	$P_p$ (\$/kg)	$P_E$ (\$/kg)	$P_A$ (\$/kg)	$P_B$ (\$/kg)
1	5554,1	125,91	370,3	555,42
2	3143,92	25,92	156,23	114,34

### 5.3 Objetivo dinâmico e simultâneo (problemas 2 e 3)

O controlador IHMPC requer um modelo linear do processo, por meio do qual a cada instante de tempo realiza-se a previsão das respostas futuras do sistema e calcula-se a sequência de ações de controle ótimas em seu problema de otimização quadrática.

Em ambas etapas (problema 2 e 3) buscou-se avaliar diferentes alternativas para esses modelos: identificação de modelos lineares a partir das condições de processo obtidas no problema 1, extensões adaptativas para o modelo linear baseada na linearização do modelo não linear do processo e na combinação linear de múltiplos modelos obtidos com base nas condições operacionais obtidas pela otimização do problema 1. Foram usadas diferentes estratégias de controle avançado para alcançar melhores desempenhos dinâmicos e econômicos para o projeto integrado na presença de perturbações aleatórias, programadas e não medidas.

#### 5.3.1 Identificação do modelo para o IHMPC

O modelo linear usado na primeira parte do problema foi ajustado a 1ª ordem e 2ª ordem pela resposta do processo a uma variação degrau nas variáveis manipuladas e é apresentado conforme a representação em função de transferência no domínio de Laplace através da Equação (127).

$$G_1(s) = \begin{bmatrix} \frac{-0,0261}{205,7613s+1} & \frac{0,0018}{1,0562s+1} \\ \frac{2,6909s-0,0033}{41719s^2+544,4305s+1} & \frac{-0,0007}{259,6728s+1} \end{bmatrix} \quad (127)$$

Este modelo relaciona as variáveis manipuladas ( $F_B$  e  $T_R$ ) e controladas ( $X_E$  e  $X_p$ ) do processo e foi obtido em torno do estado estacionário calculados pelo Problema 1, considerando a primeira condição de mercado.

Este modelo foi utilizado na previsão do comportamento das saídas para o controlador IHMPC. O problema de otimização buscou, em termos de variáveis

de projeto de controle, encontrar o vetor de parâmetros ótimos de sintonia  $\mathbf{c} = [q_1, q_2, r_1, r_2]$  que conduz o processo do *setpoint* obtido na primeira para o *setpoint* obtido para a segunda condição de mercado de maneira rápida e suave. A trajetória desejada é obtida através de uma variação nos valores desejados e calculada por uma função de comportamento de primeira ordem no tempo discreto. As variáveis  $q_1$  e  $q_2$  são os parâmetros do controlador que correspondem aos pesos no erro das saídas controladas em relação ao seu *setpoint* e formam a matriz  $Q = \text{diag}([q_1, q_2])$ , enquanto  $r_1$  e  $r_2$  representam os pesos dos esforços realizados pelo controlador nas variáveis manipuladas para manter as variáveis em seus valores desejados, formando a matriz  $R = \text{diag}([r_1, r_2])$ .

### 5.3.2 IHMPC usando um modelo linear adaptativo com atualizações em cada instante de tempo

A estratégia adaptativa consiste em linearizar via expansão por série de Taylor o modelo não linear do reator Williams-Otto, conforme apresentado nas Equações (109) a (114). O modelo resultante é atualizado em cada instante de tempo, com base no estado estacionário correspondente às condições de processo enviadas pelo controlador ao processo (ação de controle). Dessa forma, o modelo se ajusta às novas condições de operação se houver mudanças no processo provenientes de alterações no *setpoint* ou perturbações. Partindo da representação do modelo em espaço de estados apresentada nas equações (10) e (11), definem-se as matrizes A, B e C como:

$$\mathbf{A}(k) = \begin{bmatrix} \frac{\partial X_A}{\partial X_A} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_A}{\partial X_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_A}{\partial X_C} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_A}{\partial X_E} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_A}{\partial X_G} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_A}{\partial X_P} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_B}{\partial X_A} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_B}{\partial X_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_B}{\partial X_C} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_B}{\partial X_E} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_B}{\partial X_G} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_B}{\partial X_P} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_C}{\partial X_A} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_C}{\partial X_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_C}{\partial X_C} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_C}{\partial X_E} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_C}{\partial X_G} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_C}{\partial X_P} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_E}{\partial X_A} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_E}{\partial X_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_E}{\partial X_C} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_E}{\partial X_E} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_E}{\partial X_G} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_E}{\partial X_P} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_G}{\partial X_A} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_G}{\partial X_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_G}{\partial X_C} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_G}{\partial X_E} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_G}{\partial X_G} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_G}{\partial X_P} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_P}{\partial X_A} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_P}{\partial X_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_P}{\partial X_C} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_P}{\partial X_E} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_P}{\partial X_G} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_P}{\partial X_P} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \end{bmatrix} \quad (128)$$

$$\mathbf{B}(k) = \begin{bmatrix} \frac{\partial X_A}{\partial F_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_A}{\partial T_R} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_B}{\partial F_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_B}{\partial T_R} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_C}{\partial F_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_C}{\partial T_R} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_E}{\partial F_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_E}{\partial T_R} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_G}{\partial F_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_G}{\partial T_R} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \\ \frac{\partial X_P}{\partial F_B} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} & \frac{\partial X_P}{\partial T_R} \Big|_{\bar{\mathbf{x}}, \bar{\mathbf{u}}} \end{bmatrix} \quad (129)$$

$$\mathbf{C} = \begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (130)$$

$\bar{\mathbf{x}}$  e  $\bar{\mathbf{u}}$  são os valores em estado estacionário das variáveis de estado e das entradas, baseado na predição oferecida por este modelo, o problema de otimização busca, além das variáveis de projeto de processos, encontrar o vetor

de parâmetros ótimos de sintonia do controlador  $\mathbf{c} = [q_1, q_2, r_1, r_2]$  que conduz o processo entre os *setpoints* obtidos para a primeira e a segunda condição de mercado de maneira rápida e suave. A adaptação às novas condições visa solucionar problemas gerados pela má combinação do modelo de predição ao modelo real não linear do processo ao ocorrerem variações nas condições operacionais da planta.

### 5.3.3 Integração do IHMPC Adaptativo com RTO

Nesta etapa, buscou-se implementar uma estrutura de controle em que o controlador IHMPC foi integrado a uma camada RTO, com o objetivo de melhorar o desempenho do projeto simultâneo.

Diferentes projetos em estado estacionário foram avaliados por meio de índices econômico e dinâmico, quando o processo opera em modo dinâmico. Dessa forma, buscou-se justificar a necessidade de projetos simultâneos também para uma estrutura que integra o controlador com uma camada de otimização econômica. Os quatro projetos foram obtidos a partir da otimização do problema 1, proposto nesta metodologia, para 4 cenários de mercado, como apresentados na **Erro! Fonte de referência não encontrada.** e na **Erro! Fonte de referência não encontrada..**

Tabela 3 - Preços dos compostos reacionais para as condições 3 e 4.

Condição de mercado	$P_p$ (\$/kg)	$P_E$ (\$/kg)	$P_A$ (\$/kg)	$P_B$ (\$/kg)
3	4243,92	185,92	456,23	344,34
4	2443,92	285,92	556,23	144,34

O objetivo econômico da camada RTO é maximizar o lucro do reator, dado em \$/s. Considerou-se que o excesso de calor gerado pela reação pode ser removido sem custo adicional. Dessa forma, a função de lucro por instante de operação do reator é dada conforme a equação abaixo.

$$f_{RTO} = P_p (F_A + F_B) X_p + P_E (F_A + F_B) X_E - P_A F_A - P_B F_B \quad (131)$$

Cada um dos projetos obtidos pela otimização estacionária do problema 1 foi simulado utilizando modelos lineares ajustados a 1ª ordem e 2ª ordem pela

resposta do processo a variações do tipo degrau nas variáveis manipuladas. As regiões operacionais em torno das quais os modelos foram identificados foram obtidas através da otimização do Problema 1. Sua representação em função de transferência no domínio de Laplace pode ser vista nas Equações (127), (132), (133) e (134).

$$G_2(s) = \begin{bmatrix} \frac{-0,0165}{119,1469s+1} & \frac{0,1714s+0,0007}{127,5348s^2+197,2963s+1} \\ \frac{-0,0046}{65,7462s+1} & \frac{0,0336s-0,0002}{1087,0747s^2+129,0376s+1} \end{bmatrix} \quad (132)$$

$$G_3(s) = \begin{bmatrix} \frac{-0,0256}{178,6000s+1} & \frac{0,2135+0,0015}{2095,5574s^2+107,7116+1} \\ \frac{-2,2778s-0,0041}{33300,0333s^2+467,8654s+1} & \frac{0,06577-0,0005}{1529,2858s^2+171,1271s+1} \end{bmatrix} \quad (133)$$

$$G_3(s) = \begin{bmatrix} \frac{-0,0202}{139,8406s+1} & \frac{0,1312s+6,5686e-4}{165,1255s^2+173,8771s+1} \\ \frac{-0,0046(s/kg)}{56,4016s+1} & \frac{-3.8567e-4}{179,4688s+1} \end{bmatrix} \quad (134)$$

Duas estratégias adaptativas foram usadas nesta etapa para obter o projeto simultâneo ótimo. A primeira buscou atualizar os parâmetros do modelo de predição, conforme discutido na seção anterior. A segunda usa os modelos obtidos para as condições de mercado 1 e 2, calculando uma combinação linear das suas ações de controle, conforme apresentada metodologia deste presente estudo.

É preciso salientar que, como  $y^{sp}$  é uma variável de otimização nessa estrutura, a camada RTO fornece os valores de referência, ou seja, condições operacionais econômicas ótimas, que por sua vez são utilizadas no cálculo da trajetória de referência ótima a ser seguida pelo processo, conforme as Equações (97) e (98).

## 6 RESULTADOS

Neste capítulo, os resultados obtidos a partir da metodologia SPDC proposta são apresentados e discutidos. A seção segue a ordem destacada no capítulo 5, apresentado os resultados para o primeiro estudo de caso com os seus desdobramentos e, por fim, os resultados para o segundo estudo de caso são apresentados.

Os resultados de projeto simultâneo do reator de Williams-Otto foram avaliados nesta tese para a configuração do projeto ótimo considerando 3 estratégias de controle diferentes. Na primeira, foi utilizado um controlador MPC de horizonte infinito. O modelo de predição foi obtido por identificação a partir da região ótima dada pela otimização econômica do processo (problema 1), para a condição de mercado 1. A segunda proposta teve como objetivo considerar a implementação de uma estratégia adaptativa para o modelo do MPC. Nesta estratégia, o modelo foi atualizado de acordo com as alterações nas condições do processo, buscando compatibilizar suas saídas com a da dinâmica não linear do reator. Por último, uma estratégia de integração do MPC de horizonte infinito com uma RTO em três camadas foi utilizada, com o intuito de obter um projeto integrado que ofereça ainda mais vantagens econômicas. Nesta última etapa do trabalho, duas estratégias de adaptação foram comparadas a fim de observar a mais vantajosa do ponto de vista econômico e dinâmico do projeto simultâneo.

### ***6.1 Projeto simultâneo de processos e de seu sistema de controle usando um IHMPC nominal***

Nesta seção, os resultados obtidos por meio da metodologia SPDC proposta são apresentados e discutidos para o caso em que um único modelo obtido em uma única região operacional (referente à primeira condição de mercado). A Tabela 4 apresenta as restrições e os resultados da otimização em estado estacionário que calcula as duas condições de mercado com as condições de operação, a variável de projeto e os valores utópicos dos objetivos econômicos, calculados no Problema 1.

Tabela 4 - Restrições e resultados do Problema 1 para cada condição de mercado.

Variáveis		$d = W$	$\mathbf{u} = [F_B; T_R]$	$\mathbf{y} = [X_E; X_P]$	$\phi_{eco}^{Ur}$
Unidades		[kg]	[kg/s; °C]	[-; -]	[%]
Restrições	Mínimo	[2000]	[2; 50]	[0; 0]	-
	Máximo	[3000]	[10; 150]	[1; 1]	-
Valores ótimos	Condição 1	2118,16	[4,20; 85,97]	[0,2951; 0,1103]	1,01e6
	Condição 2	2000	[8,98; 107,60]	[0,2265; 0,0909]	3,65e6

O Problema 2 é resolvido usando os valores operacionais ótimos das duas condições de mercado. Os valores ótimos das variáveis de saída são usados como os dois *setpoints* de transição ( $y^{sp1}$  e  $y^{sp2}$ ) para calcular a trajetória de referência a ser otimizada ( $y^{ref}$ ). O problema é configurado com um tempo de amostragem de  $\Delta t = 30s$  e um horizonte de controle  $m = 3$ . As restrições dos Problema 2, que também são válidas para o Problema 3, são apresentadas na Tabela 5.

Tabela 5 - Restrições para as variáveis de otimização dos problemas 2 e 3.

Variáveis	Unidades	Mínimo	Máximo
$q_1$	[-]	0,001	1000
$q_2$	[-]	0,001	1000
$r_1$	[-]	0,001	1000
$r_2$	[-]	0,001	1000
$\mathbf{u} = [F_B; T_R]$	[kg/s; °C]	[2; 50]	[10; 150]
$d = W$	[kg]	2000	3000

As restrições do processo foram escolhidas de acordo com a literatura e as restrições referentes aos parâmetros de sintonia do controlador foram atribuídas com a limitação de que os valores devem ser positivos (limite inferior). Além disso, uma faixa abrangente de busca dos valores dos parâmetros de sintonia foi escolhida de modo que os limites superiores foram definidos como 1000. A Tabela 6 apresenta os resultados do Problema 2. Nesta etapa, o sistema de controle é operado para conduzir otimamente o reator da condição de mercado 1 para a condição 2, minimizando a soma quadrática ponderada do erro entre a

saída do processo e a trajetória ideal de primeira ordem. O resultado fornece os parâmetros de sintonia  $\mathbf{Q}$  e  $\mathbf{R}$  do controlador IHMPC e as condições ótimas de estado estacionário ( $\mathbf{u}$ ), considerando apenas o aspecto dinâmico da minimização do erro quadrático. Os pesos atribuídos à soma dos erros foram obtidos de forma heurística, através de conhecimento e observação prévia do comportamento das variáveis controladas e atribuídos como  $\mathbf{T} = \text{diag}([1,100])$ .

Tabela 6 - Solução ótima do Problema 2.

Variáveis	Unidades	Valores
$q_1$	[-]	987,58
$q_2$	[-]	999,77
$r_1$	[-]	9,83
$r_2$	[-]	111,19
$\mathbf{u} = [F_B; T_R]$	[kg/s; °C]	[5,85; 95,69]
$d = W$	[kg]	2740,66
$\phi_{din}^{Ur}$	[-]	0,0062

A solução do problema integrado é encontrada ao resolver o Problema 3 usando a função *direct* (FINKEL, 2003) e a função *fgoalattain* do Matlab®, calculando assim de forma simultânea os parâmetros de sintonia do MPC (matrizes  $\mathbf{Q}$  e  $\mathbf{R}$ ) e as condições operacionais ótimas ( $\mathbf{u}$ ). A Tabela 7 apresenta os resultados do Problema 3 com os valores das variáveis de otimização e os valores dos objetivos econômicos e dinâmicos.

Tabela 7 - Solução ótima do Problema 3.

Variáveis	Unidades	Custo Quadrático	Alcance de metas
$\Omega_{eco}; \Phi_{eco}$	[-;-]	[100;100]	[1;1]
$\Omega_{din}; \Phi_{din}$	[-;-]	[10]	[1]
$q_1$	[-]	974,62	986,94
$q_2$	[-]	999,31	992,58
$r_1$	[-]	8,92	9,21
$r_2$	[-]	121,40	79,47
$\mathbf{u} = [F_B; T_R]$	[kg/s; °C]	[5,56;94,51]	[4,81;88,34]
$d = W$	[kg]	2670,09	2678,91
$\phi_{din}$	[-]	0,0062	0,0065
$\phi_{eco} = [\phi_{eco}^1; \phi_{eco}^2]$	[%; %]	[7,88e5; 3,7057e6]	[9,50e5; 3,85e6]

Ambas propostas de solução do problema simultâneo apresentado neste trabalho buscam atingir os valores utópicos de cada objetivo (maximizando o objetivo econômico e minimizando o objetivo dinâmico). É importante notar que para o método de alcance de metas um peso igual a 1 permite que os componentes alvos alcancem valores menores ou maiores que os valores desejados. As restrições do problema, entretanto, podem evitar que valores sejam iguais ao valor utópico de cada objetivo (HULTGREN; IKONEN; KOVÁCS, 2019).

Os resultados dos projetos simultâneos obtidos pelo alcance de metas (AM) e pelo cálculo da função em custo quadrático (CQ) foram comparados em dois cenários distintos de operação do processo. No primeiro cenário, a estrutura busca rastrear a variação no valor dos *setpoints* das variáveis controladas, causados pela variação no preço dos produtos e reagentes. O segundo cenário avalia a capacidade de rejeição de perturbação no sistema para distúrbios na vazão de alimentação do reagente A ( $F_A$ ) em diferentes instantes de tempo. Os projetos integrados ótimos obtidos são comparados com uma sintonia padrão (PAD) para a qual os parâmetros são  $\mathbf{Q} = \text{diag}([1,1])$  e  $\mathbf{R} = \text{diag}([1,1])$ . Esses parâmetros representam uma sintonia intuitiva para o controlador trabalhando

com valores normalizados para as variáveis controladas e manipuladas, conforme as Equações (135) e (136).

$$\mathbf{y}_{norm} = \frac{\mathbf{y} - \mathbf{y}_{norm}^{\min}}{\mathbf{y}_{norm}^{\max} - \mathbf{y}_{norm}^{\min}} \quad (135)$$

$$\mathbf{u}_{norm} = \frac{\mathbf{u} - \mathbf{u}_{\min}}{\mathbf{u}_{\max} - \mathbf{u}_{\min}} \quad (136)$$

Os valores  $\mathbf{y}_{norm}^{\max} = [1;1]$ ,  $\mathbf{y}_{norm}^{\min} = [0;0]$ ,  $\mathbf{u}_{\max} = [11;180]$  e  $\mathbf{u}_{\min} = [1;20]$  foram utilizados no cálculo da normalização das variáveis.

A metodologia proposta é também comparada com uma metodologia sequencial (SEQ). Nesta metodologia, os resultados do problema 1 são usados para calcular os parâmetros ótimos ( $\mathbf{Q}$  e  $\mathbf{R}$ ) em um problema de otimização dinâmica, no qual a função objetivo busca minimizar o erro quadrático entre a variável controlada e sua trajetória de referência em um horizonte de simulação. Os valores obtidos para os parâmetros de sintonia do controlador na metodologia sequencial são  $\mathbf{Q} = \text{diag}([999,97;999,97])$  e  $\mathbf{R} = \text{diag}([9,63;333,36])$ .

Dois índices foram usados para calcular o desempenho dinâmico e econômico dos projetos simultâneos e compará-los com o projeto sequencial e a sintonia padrão. O primeiro calcula a integral do erro quadrático entre a variável controlada e a trajetória de referência e o segundo calcula o lucro total da planta durante o horizonte de simulação (5h).

### Cenário 1:

As variáveis controladas alcançaram a trajetória ótima de primeira ordem entre as duas condições de mercado distintas. Ambas estratégias simultâneas (CQ e AM), bem como a sequencial e a sintonia padrão, puderam minimizar a função objetivo dinâmica e demonstraram habilidade em seguir a trajetória ótima proposta pelo teste de flexibilidade proposto, fornecendo assim um ajuste ótimo para os parâmetros  $\mathbf{Q}$  e  $\mathbf{R}$  do controlador IHMPC, conforme apresentado na Figura 8. Entretanto, para alcançar tais valores e seguir a trajetória ótima proposta, houve saturação da variável manipulada  $u_1$  no seu valor máximo (Figura 9). O comportamento obtido é melhor para as abordagens de projeto comparadas à sintonia padrão, em termos de resposta transitória e velocidade

para atingir os novos valores desejados. Esse comportamento esperado e melhora no desempenho dinâmico está relacionado ao aspecto de controle considerado na função objetivo dinâmica da metodologia SPDC proposta, ou seja, a minimização da integral do erro quadrático. O esperado comportamento de saturação na variável manipulada e embora não seja um problema pode ser explicado pela ausência de um termo relacionado ao esforço de controle ou à própria variável manipulada na função objetivo do problema de otimização, causando um livre movimento nas variáveis manipuladas dentro da região viável.

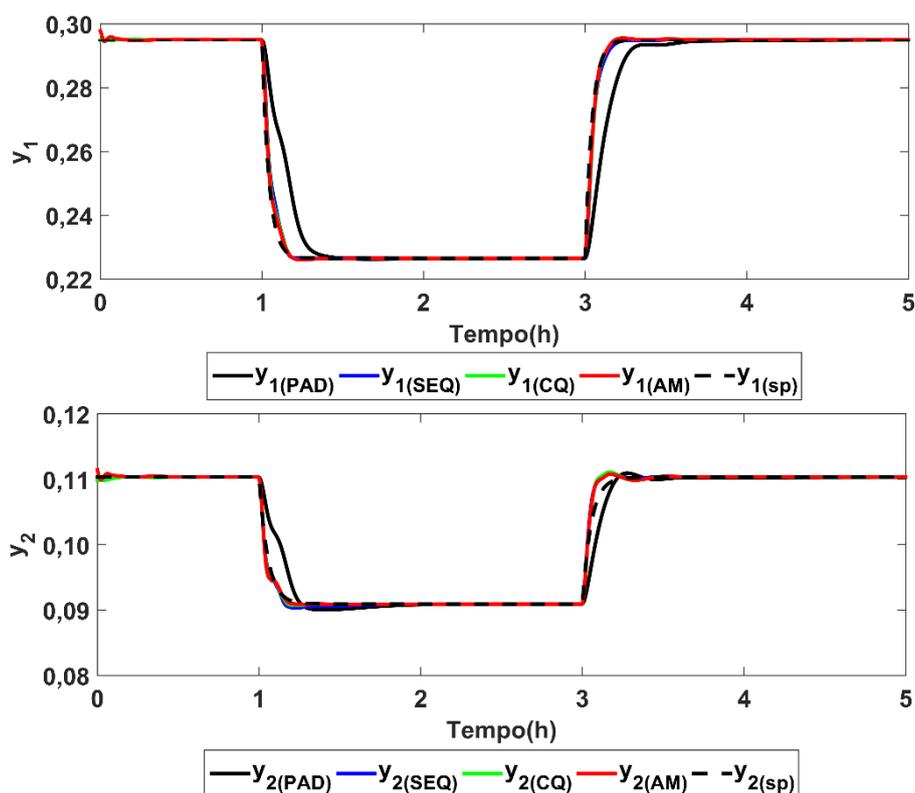


Figura 8 - Comportamento dinâmico das variáveis controladas (Cenário 1).

O controlador por sua vez, pode então alterar os valores das variáveis manipuladas enquanto rastreia de maneira ótima a trajetória proposta pelas alterações dos *setpoints*. Estados estacionários diferentes são observados devido às diferenças entre cada projeto. É importante ressaltar que as variações obedecem às restrições durante todo o horizonte de simulação, conforme apresentado pela Figura 9.

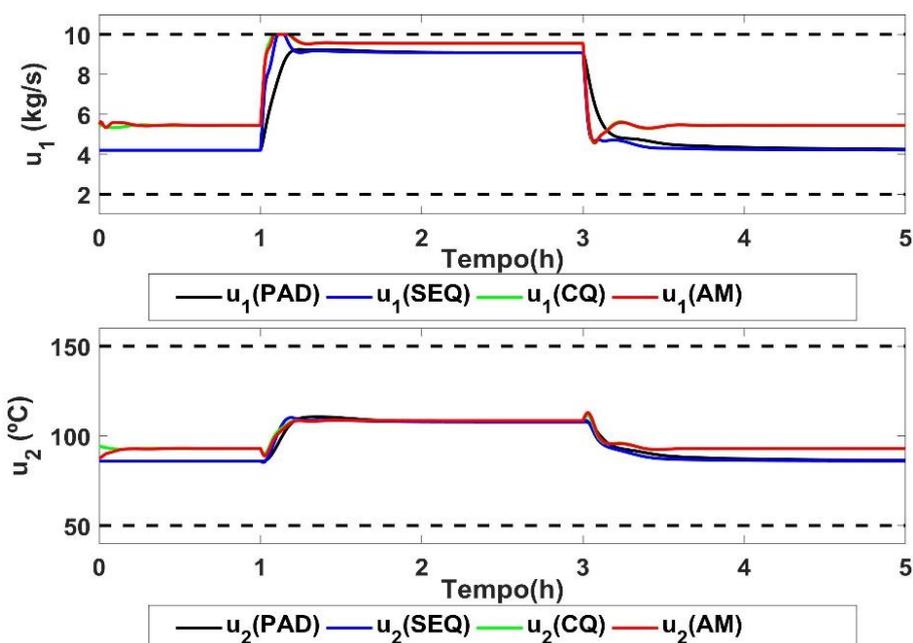


Figura 9 - Comportamento dinâmico das variáveis manipuladas (Cenário 1).

### Cenário 2:

No segundo cenário, perturbações do tipo variação degrau foram aplicadas na variável  $F_A$  nos seguintes instantes de simulação: decréscimo de 20% no tempo igual a 1h e aumento de 15% no tempo igual a 3h. Os projetos obtidos pelas metodologias SPDC demonstraram os melhores comportamentos em comparação às sintonias PAD e SEQ, em termos de rejeição de perturbação e retorno ao *setpoint* de maneira mais rápida. É possível notar um desempenho dinâmico insatisfatório na capacidade de rejeitar as perturbações na metodologia sequencial (Figura 10). Embora os modelos usados por cada configuração sejam os mesmos, obtidos na mesma região operacional (condição de mercado 1), uma explicação para o *offset* do projeto SEQ pode estar atrelado à incapacidade do projeto em estado estacionário transitar pelas novas regiões que a perturbação conduz o processo. Esta deficiência no desempenho dinâmico pode ser atribuída à característica do critério dinâmico da função objetivo avaliar somente o caso específico do rastreo para uma variação nos valores dos *setpoints* das variáveis controladas. Entretanto, embora essa formulação da função objetivo forneça mais liberdade para a variação da variável manipulada, mesmo com a condição de saturação da variável  $u_1$  (Figura 11), os valores desejados das variáveis controladas não são alcançados durante o período em que ocorrem as perturbações para as configurações SEQ e PAD.

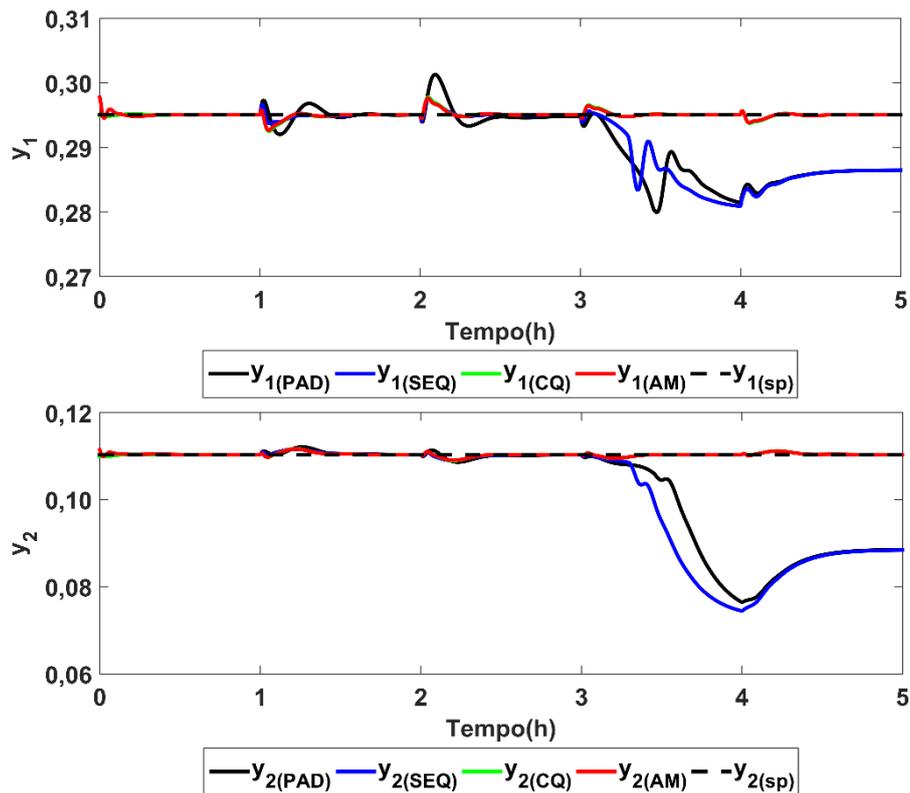


Figura 10 - Comportamento dinâmico das variáveis controladas (Cenário 2).

A Figura 11 apresenta o comportamento dinâmico das variáveis manipuladas. A pequena oscilação nos controladores obtidos pela metodologia simultânea (CQ e AM) pode ser explicada em virtude da função objetivo dinâmica não ter qualquer termo relacionado ao esforço de controle, que permite a variável manipulada mover-se livremente. Entretanto, vale a pena ressaltar que, mesmo com mais liberdade para mover-se, os valores das variáveis manipuladas respeitaram as restrições do sistema e também não houve saturação das variáveis, como observado na metodologia tradicional. Essa melhora no desempenho dinâmico pode ser explicada pelo fato de a metodologia SPDC também considerar aspectos econômicos em sua função objetivo, que está relacionada diretamente à variável manipulada  $F_B$ .

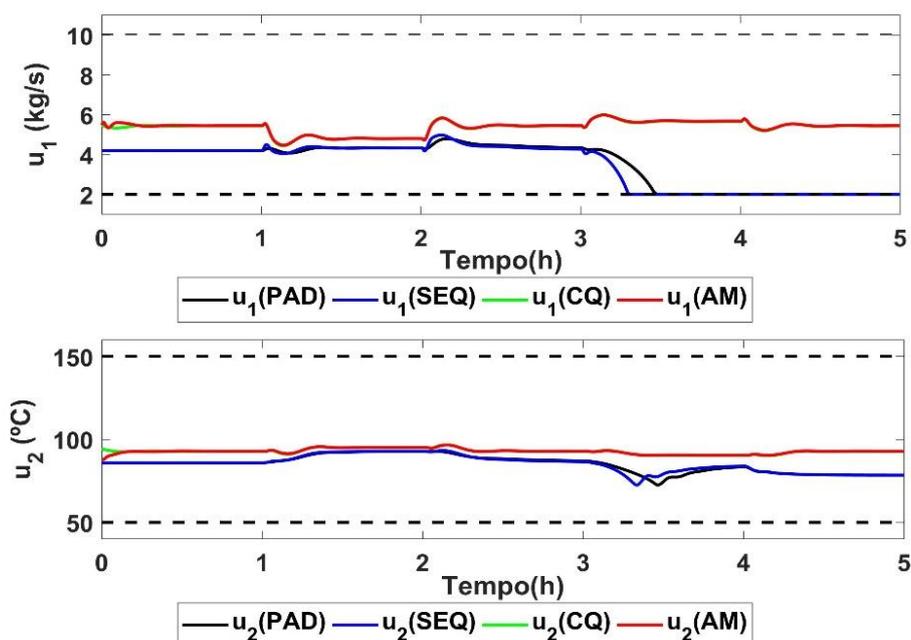


Figura 11 - Comportamento dinâmico das variáveis manipuladas (Cenário 2).

Os projetos integrados obtidos pelas metodologias SPDC propostas foram avaliados em termos dos benefícios econômicos e dinâmicos oferecidos à planta. Para isso, foi calculado a soma do lucro por unidade de tempo e a soma do erro quadrático integrada durante todo tempo de simulação (Tabela 8). A Figura 12 apresenta os custos econômicos ao longo do tempo de simulação.

Tabela 8 - Valores dos índices econômico e dinâmico.

Controladores	ISE (Cenário 1)	Lucro (\$) (Cenário 1)	ISE (Cenário 2)	Lucro (\$) (Cenário 2)
CQ	0,0033	8,34e5	2,55e-4	6,08e5
AM	0,0028	8,35e5	2,82e-4	6,10e5
PAD	0,0438	7,70e5	0,1318	4,08e5
SEQ	0,0040	7,75e5	0,1560	3,92e5

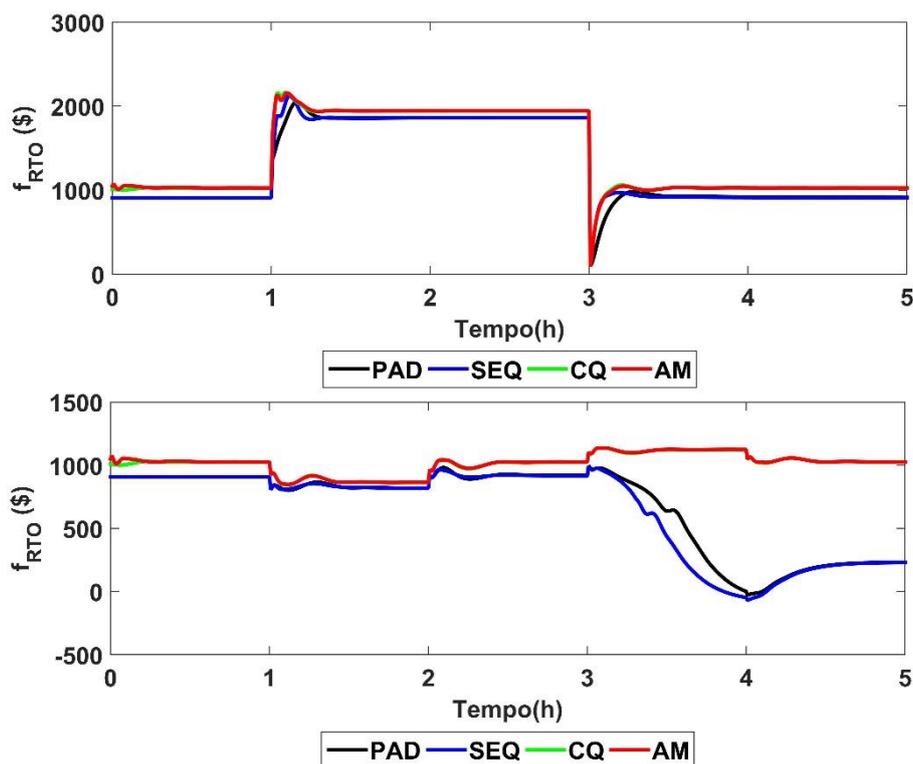


Figura 12 - Lucro ao longo do tempo de simulação para os cenários 1 e 2.

A metodologia SPDC produz os melhores resultados tanto do ponto de vista econômico (maiores lucros), quanto do ponto de vista dinâmico (menores valores de erro). No primeiro cenário, em comparação à metodologia sequencial, os projetos simultâneos obtiveram lucros de 7,60% e 7,74% maiores e erros 1,21 vezes e 1,43 vezes menores; em relação à metodologia padrão, as abordagens SPDC ofereceram projetos com lucros de 8,27% e 8,41% maiores, com erros de 13,27 vezes e 15,64 vezes menores. Em relação ao segundo cenário, as metodologias simultâneas apresentam lucros de 55,35% e 55,72% maiores e erros 612 e 554 vezes menores em comparação à metodologia sequencial; em comparação com a metodologia padrão, notam-se lucros de 48,99% e 49,5% maiores e erros de 517 e 468 menores.

Além disso, vale a pena observar que os baixos valores de lucratividade das configurações SEQ e PAD são devido à saturação na variável manipulada  $F_B$  em seu limite inferior, que por sua vez limita a saída dos produtos  $P$  e  $E$ , evitando que essas variáveis retornem aos valores desejados e consequentemente diminuindo o lucro da operação ao longo do tempo de simulação.

## **6.2 Projeto simultâneo de processos e de seu sistema de controle usando um IHMPC adaptativo**

O reator de Williams-Otto foi novamente simulado em malha fechada para 5h de operação com um tempo de amostragem de  $\Delta t = 30s$  e um horizonte de controle  $m = 3$ . A Tabela 9 apresenta os resultados para os três subproblemas da metodologia apresentada. A diferença nesta subseção é que uma estratégia adaptativa foi usada para acompanhar as mudanças nas condições operacionais do processo e atualizar os parâmetros do modelo linear do controlador IHMPC, em busca de fornecer melhor desempenho quando o sistema opera na presença de perturbações aleatórias.

Tabela 9 - Resultados do projeto simultâneo do processo e seu sistema de controle usando um controlador IHMPC adaptativo.

<b>Problema 1</b>			
Variáveis	Unidades	Valores ótimos	
		Condição 1	Condição 2
$d = W$	[kg]	2118,16	2000
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[4,20; 85,97]	[8,98; 107,60]
$\mathbf{y}^{sp} = [X_E; X_P]$	[-; -]	[0,2950; 0,1103]	[0,2265; 0,0901]
$\phi_{eco}^{Ur}$	[%]	1,01e6	3,65e6
<b>Problema 2</b>			
Variáveis	Unidades	Valores ótimos	
$q_1$	[-]	956,96	
$q_2$	[-]	950,54	
$r_1$	[-]	292,11	
$r_2$	[-]	41,14	
$d = W$	[kg]	2275,64	
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[5,04; 91,09]	
$\phi_{din}^{Ur}$	[-]	0,0031	
<b>Problema 3</b>			
Variáveis	Unidades	Valores ótimos	
		Método CQ	Método AM
$q_1$	[-]	947,65	919,87
$q_2$	[-]	962,73	993,44
$r_1$	[-]	294,24	292,13
$r_2$	[-]	39,10	39,58
$d = W$	[kg]	2296,07	2296,02
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[4,94; 90,08]	[5,27; 91,76]
$\phi_{din}$	[-]	0,0031	0,0035
$[\phi_{eco}^1; \phi_{eco}^2]$	[%; %]	[9,39e5; 4,25e6]	[9,17e5; 4,31e6]

Os projetos simultâneos obtidos usando o IHMPC adaptativo (representados pela sigla “Adp”) foram comparados com os controladores da seção anterior (representado pela sigla “Lin”), obtidos pela ferramenta de identificação de sistema do Matlab®. O sistema foi simulado em 2 condições diferentes: busca pelo novo *setpoint* e rejeição de perturbação.

### Cenário 1:

No primeiro cenário, o sistema foi submetido à mudanças nos valores desejados e o objetivo foi alcançar as novas condições através de uma trajetória de primeira ordem entre os estados.

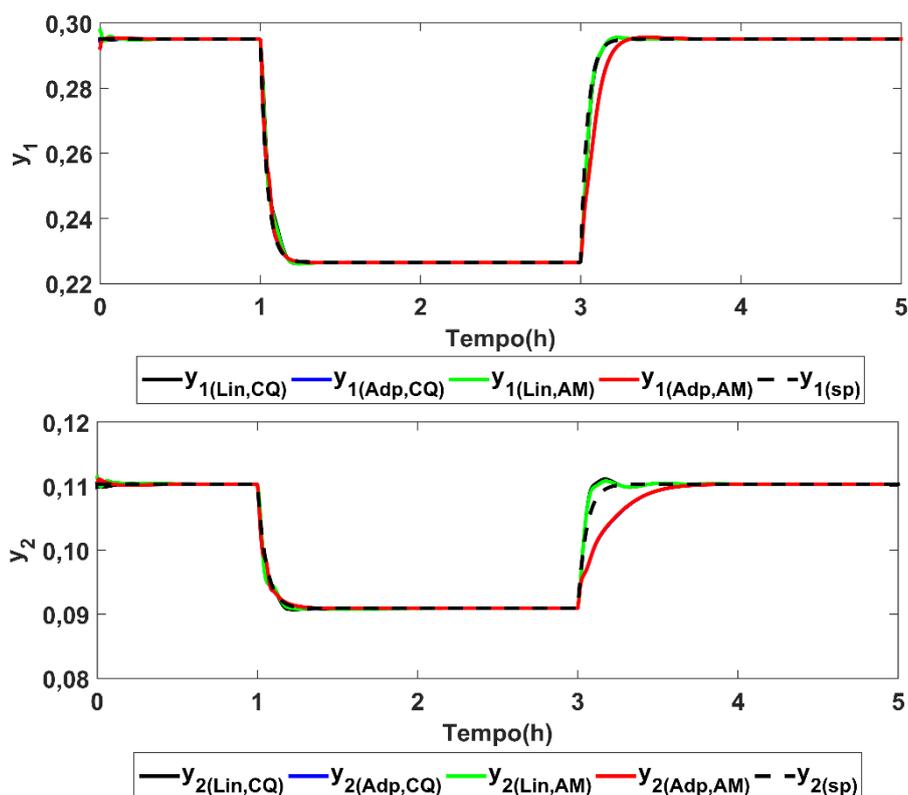


Figura 13 - Comportamento dinâmico das variáveis controladas (Cenário 1).

É possível notar que para as variáveis controladas, os controladores adaptativos obtiveram um comportamento mais lento ao voltar para o estado estacionário original (Figura 13). Tal comportamento pode ser explicado em virtude do comportamento mais conservador das variáveis manipuladas em atingirem as novas condições de operação impostas pela alteração do mercado (Figura 14). A característica adaptativa do controlador permite que ele melhore a previsão em detrimento de mudar abruptamente as variáveis manipuladas, capture as alterações nos ganhos do sistema, conforme apresentado na Figura

15 e evite deterioração ou mau funcionamento de atuadores. Além disso, vale a pena destacar que os projetos simultâneos utilizando a abordagem adaptativa forneceram controladores que atribuem mais importância à variação da variável  $u_1$  (visto no maior valor numérico da variável  $r_1$  em comparação ao controlador linearizado em uma única condição). Como o valor numérico mais alto deste parâmetro, o controlador é mais conservador ao aumentar ou diminuir o valor da variável, protegendo o equipamento e consequentemente alcançando o novo estado estacionário de maneira mais lenta.

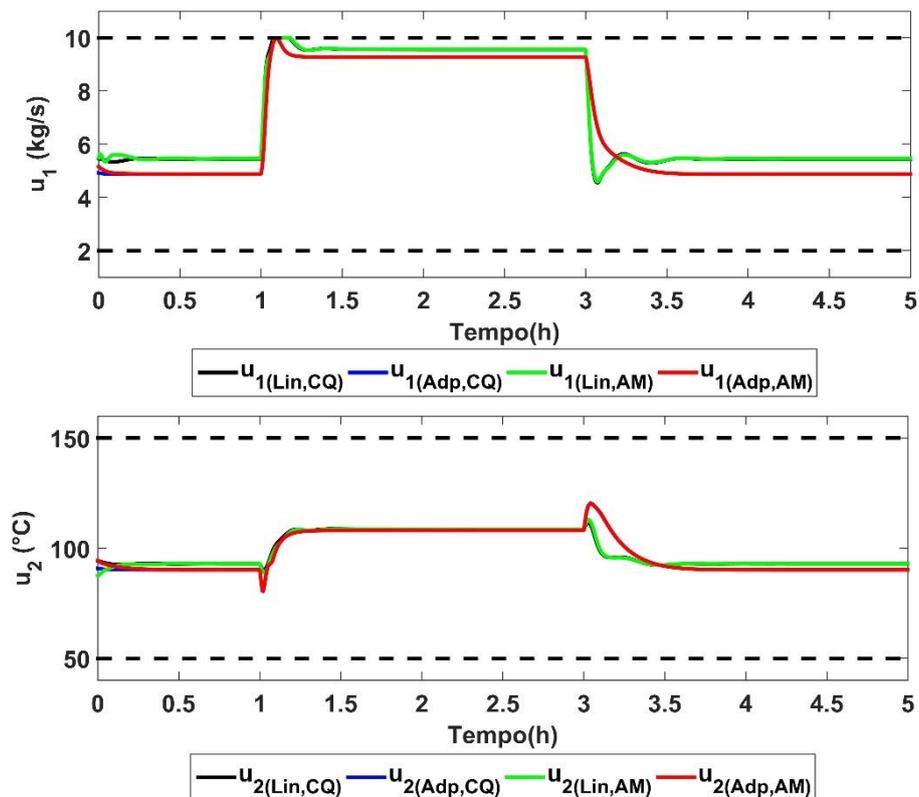


Figura 14 - Comportamento dinâmico das variáveis manipuladas (Cenário 1).

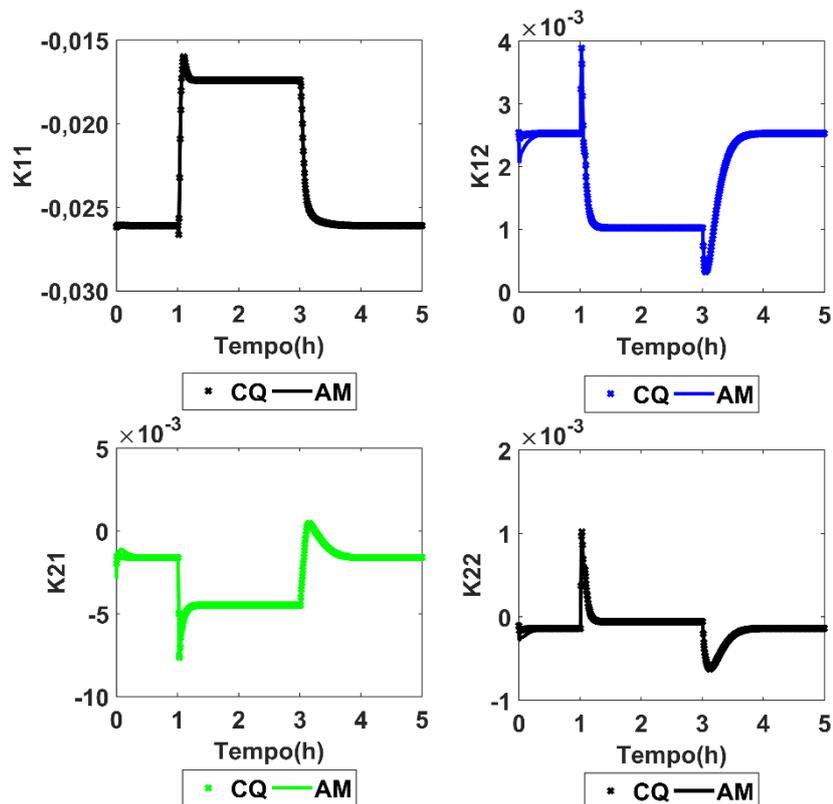


Figura 15 - Alterações nos ganhos dos modelos (Cenário 1).

### Cenário 2:

No segundo cenário, o sistema foi submetido a variações aleatórias do com a função na variável de perturbação  $F_A$  a cada 60s de operação. Essas variações foram geradas utilizando a função de números aleatórios do *Matlab* e uma semente pseudoaleatória, para garantir a mesma distribuição em todas as comparações e são apresentadas na Figura 16.

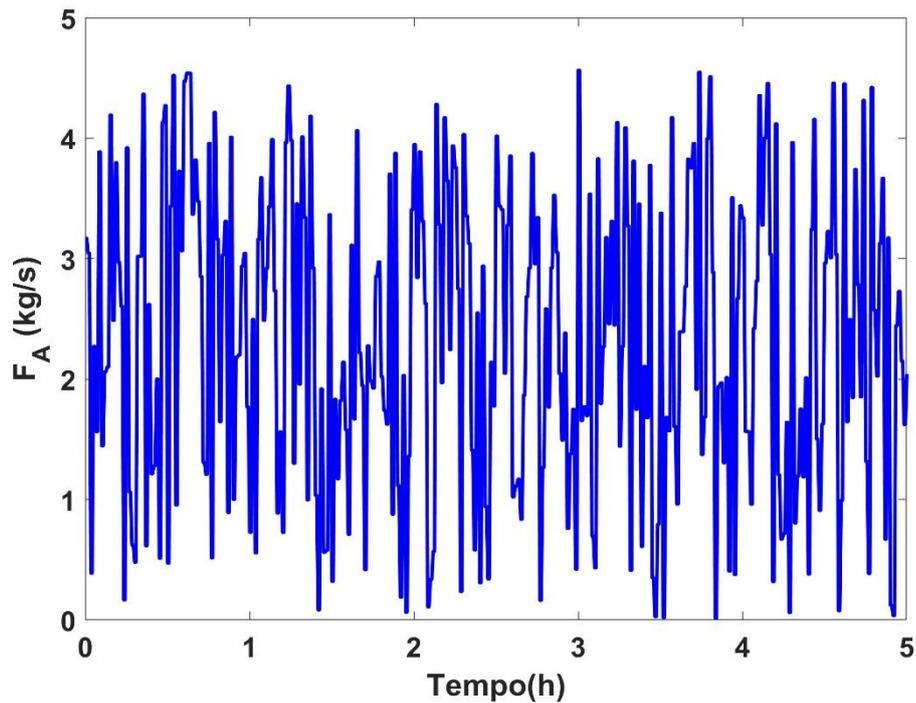


Figura 16 - Variações aleatórias na variável perturbação ( $F_A$ ).

A Figura 17 apresenta os comportamentos das variáveis controladas observado devido a variação aleatória em que o sistema está sujeito.

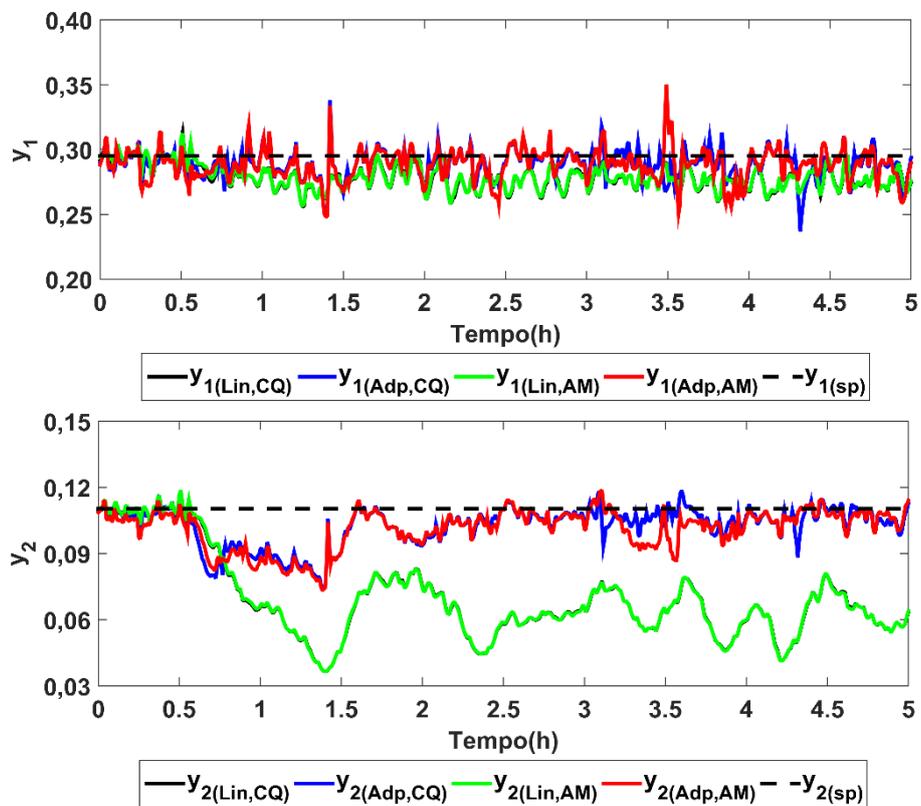


Figura 17 - Comportamento dinâmico das variáveis controladas (Cenário 2).

Como uma consequência das variações aleatórias, observa-se um comportamento oscilatório nas variáveis controladas para ambos os casos. Entretanto, os projetos simultâneos com os controladores adaptativos conseguiram amenizar melhor as oscilações recebidas. Com isso, tais controladores puderam manter as variáveis controladas com os valores mais próximos possíveis dos *setpoints* (linha preta tracejada). O projeto simultâneo considerando um modelo linearizado em apenas uma condição operacional obteve um excelente desempenho. Por exemplo, para o primeiro cenário, devido às características comentadas acima, obteve erros de 2,67 e 3,21 vezes menores, lucros de 5,16% e 5,3% maiores (Tabela 10). Entretanto, quando submetido a um processo altamente não linear, ruidoso e de comportamento de inversão de ganho, o controlador pode falhar e não conseguir manter o processo em seus respectivos valores desejados, conforme observado no comportamento da variável  $y_2$ .

Esta insuficiência pode ser explicada em virtude da perda da capacidade do sistema em prever o comportamento desejado devido à inversão do ganho do sistema apresentado durante maior parte do momento em que o sistema é submetido à variação aleatória na variável  $F_A$ , conforme apresentado na Figura 18.

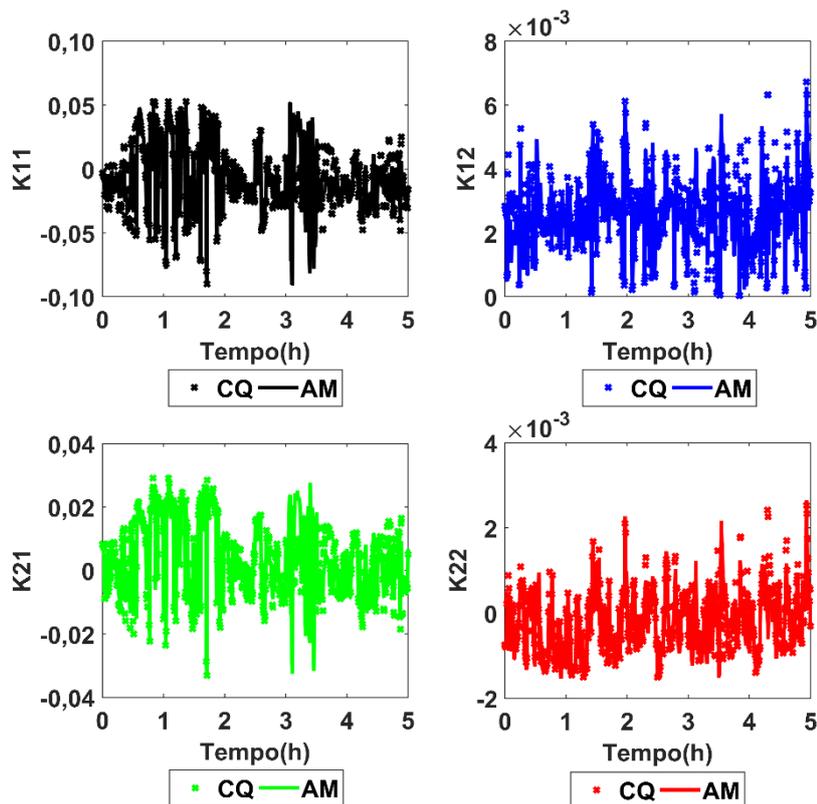


Figura 18 - Alterações nos ganhos dos modelos (Cenário 2).

Outro fator importante a ser observado está ligado à saturação observada no valor da variável manipulada  $F_B$  no comportamento do controlador linearizado na condição nominal da primeira condição de mercado. Em virtude das perturbações aleatórias em que o processo está submetido, este é levado para diferentes regiões operacionais, nas quais, nem sempre um único modelo linear pode prever com eficiência o seu comportamento.

O modelo de previsão recebe as informações sobre as variações nas condições operacionais do processo e leva a variável  $u_1$  até o valor limite inferior de saturação (Figura 19). Como foi linearizado em torno de uma condição de operação específica, o modelo se perde devido às características do processo e não pode retornar à condição próxima aos valores anteriores. Assim, o sistema de controle fica impedido de manter os valores das variáveis controladas o mais próximo possível dos *setpoints* (Figura 17). Em contrapartida, os controladores adaptativos atualizam os seus parâmetros para as novas condições de estado estacionário correspondente às novas condições em que o sistema se encontra e consegue então adaptar-se à essas mudanças e retornar aos valores

desejados mesmo com perturbações aleatórias ocorrendo nas variáveis do processo.

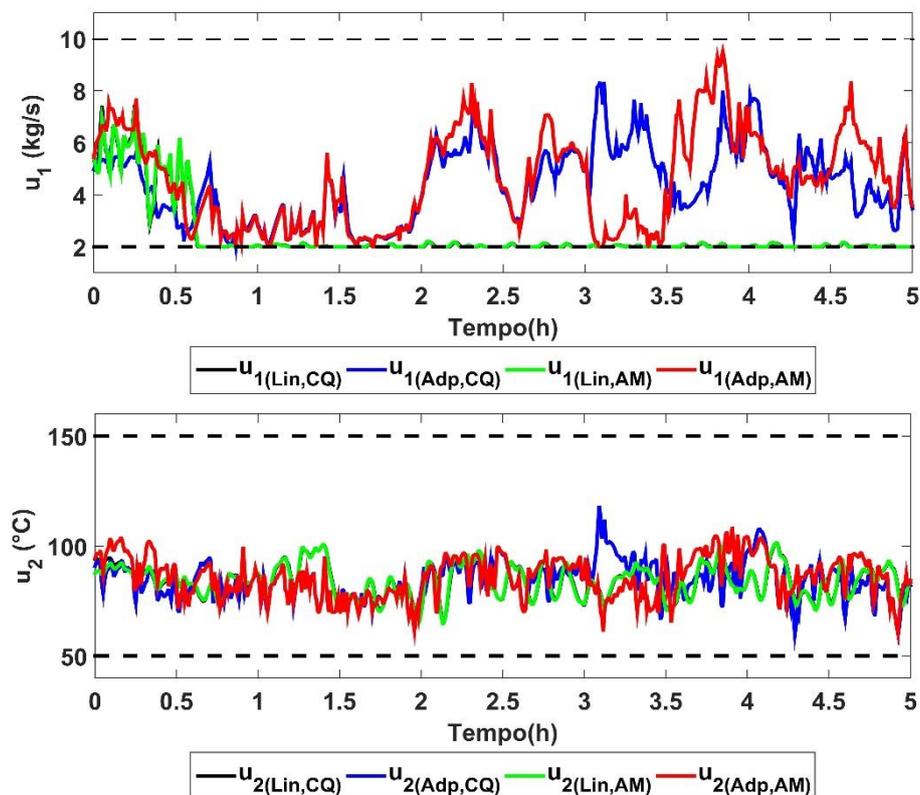


Figura 19 - Comportamento dinâmico das variáveis manipuladas (Cenário 2).

Em virtude da ineficiência dos controladores linearizados em apenas uma condição de operação, os controladores adaptativos obtiveram benefícios em relação a ambos os critérios, dinâmicos e econômicos. Os erros representaram valores de 7,96 e 6,69 vezes em comparação aos controladores com modelo linearizado em uma condição. É necessário ressaltar, entretanto, que os projetos obtidos através da consideração adaptativa do modelo linear no cenário de perturbação aleatório ocasionaram uma amplificação do comportamento aleatório do sistema. Esse comportamento pode ser prejudicial às variáveis de manipulação como vazões, em que a abertura e fechamento brusco de uma válvula pode levar ao mau funcionamento do equipamento. Contudo, nota-se que apenas os controladores adaptativos conseguiram uma condição em que a integral da função econômica retornou lucro no tempo de operação da planta (Tabela 10).

Tabela 10 - Índices econômicos e dinâmicos para ambos os cenários.

Cenário	Índice	CQ – Adp	CQ – Lin	AM – Adp	AM – Lin
1	Lucro (\$/s)	7,93e5	8,34e5	7,93e5	8,35e5
	ISE	0,0088	0,0033	0,0090	0,0028
2	Lucro (\$/s)	4,64e5	-5,77e4	4,50e5	-5,65e4
	ISE	0,18	1,43	0,21	1,42

Vale ressaltar que a condição de prejuízo apresentada na simulação do cenário 2 para os controladores linearizados em torno de apenas um estado estacionário, conforme notada pela avaliação da Tabela 10 e pela Figura 20 deve-se ao fato de o processo levar à variável  $u_1$  até o seu limite inferior (Figura 19). Devido à essa condição, que representa uma menor concentração do reagente  $B$  disponível, a produção de  $P$  e  $E$  também diminui e os controladores não conseguem fazer com que essas variáveis retornem aos valores desejados. Tal comportamento reflete em uma condição em que menores lucros podem ser obtidos na operação, quando os controladores linearizados em só uma região operacional são comparados aos projetos usando a abordagem adaptativa proposta. Além disso, como observado na soma total do lucro, o sistema pode ser levado à condição extrema de prejuízo se a variável  $u_1$  permanecer em seu limite inferior por longos períodos.

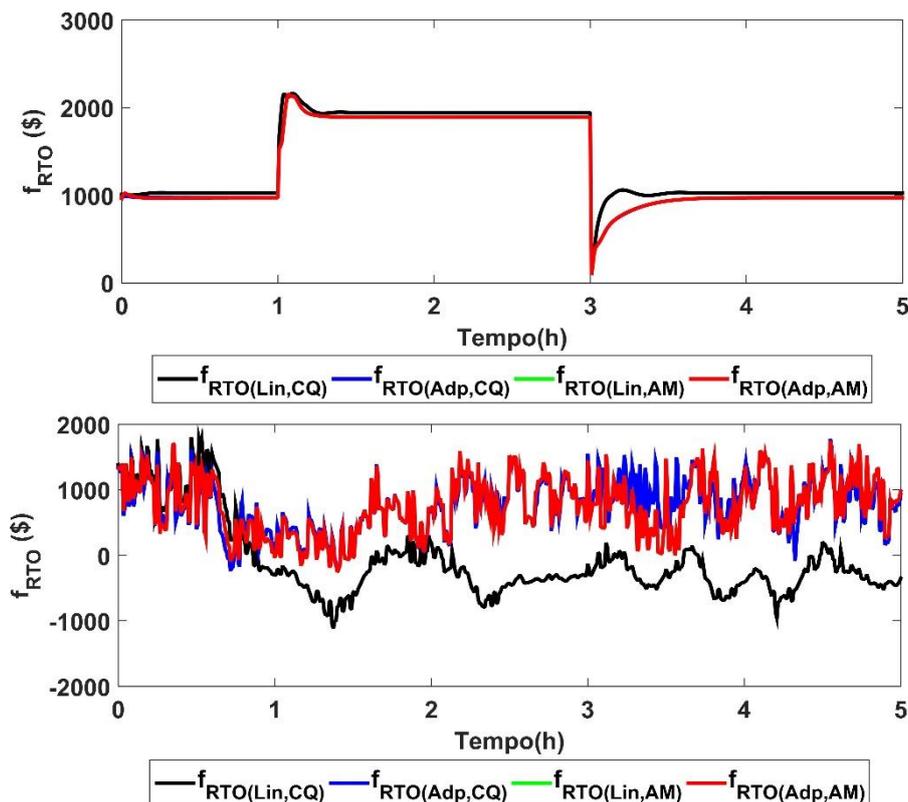


Figura 20 – Lucro obtido a cada instante de simulação.

### 6.3 Projeto simultâneo de processos e de seu sistema de controle usando um IHMPC adaptativo em uma estrutura de MPC e RTO

Esta seção tem como objetivo avaliar a capacidade de controle de uma estrutura integrada entre o controlador IHMPC e a camada de otimização RTO, através de simulação computacional. Primeiramente foi realizado um estudo financeiro de diferentes projetos de processos, gerados em diferentes condições operacionais. Os sistemas otimizados foram submetidos às variações ocasionadas pelas alterações nos preços, bem como perturbações que também alteram o ótimo econômico do sistema. Nestes cenários, a metodologia tradicional de projeto de processos em uma abordagem sequencial apresenta limitações. Dessa forma, para um determinado projeto, ótimo economicamente do ponto de vista estacionário, os melhores lucros nem sempre são garantidos na operação dinâmica do sistema.

A abordagem simultânea de tratar o problema de projeto de projeto de processos e de controle foi também aplicada para este problema. Foi

considerado a avaliação de 3 estratégias diferentes para garantir a avaliação de incertezas dos parâmetros dos modelos do controladores, a saber, a estrutura adaptativa proposta neste trabalho, uma estrutura de múltiplos modelos e uma estrutura robusta.

### 6.3.1 Análise financeira de múltiplos projetos

Esta seção consiste em realizar uma avaliação financeira de diferentes projetos e comparar os desempenhos entre si, levando em consideração também os índices econômicos baseados em estado estacionário. Para isso, foi proposta uma metodologia em que o projeto tradicional em estado estacionário foi realizado para as diferentes condições de mercado. Baseado no problema 1 da metodologia SPDC apresentada neste texto (otimização econômica), diferentes alternativas de projetos foram obtidas, juntamente com suas condições operacionais. Com os valores obtidos na primeira etapa, foi possível gerar os modelos, conforme apresentados nas Equações (127), (132), (133) e (134) e depois realizar a simulação dinâmica destes projetos em uma estrutura de controle com a integração das camadas do controlador IHMPC e da otimização RTO.

Os diferentes projetos em estado estacionário foram obtidos por meio de otimização não linear com a função *fmincon* do Matlab (com os valores *default*). Os valores da função objetivo maximizada, bem como os valores operacionais ótimos em estado estacionário e a variável de projeto, representada pelo tamanho do reator (dado pela quantidade de massa em seu interior) são apresentados na Tabela 11.

Tabela 11 - Retorno esperado e condições operacionais ótimas.

<b>Variáveis</b>		$d = W$	$\mathbf{u} = [F_B; T_R]$	$\mathbf{y} = [X_E; X_P]$	$\phi_{eco}$
Unidades		kg	[kg / s; °C]	[-; -]	%
Restrições	Mínimo	2000	[2;50]	[0;0]	-
	Máximo	3000	[10;150]	[1;1]	-
Condições de mercado	1	2118,16	[4,20; 85,97]	[0,2951; 0,1103]	1,01e6
	2	2000	[8,98; 107,60]	[0,2265; 0,0909]	3,65e6
	3	2000	[5,30; 94,16]	[0,2854; 0,1073]	1,30e6
	4	2000	[7,32; 105,72]	[0,2571; 0,0984]	1,11e6

Na segunda etapa, o sistema foi avaliado financeiramente por meio de uma simulação dinâmica. Os resultados foram obtidos avaliando dois cenários distintos, envolvendo mudanças nas condições de mercado e em duas variáveis de perturbação do sistema ( $F_A$  e  $k_{20}$ ).

As restrições no esforço de controle e os parâmetros de simulação e de controle da estrutura integrada do IHMPC com a RTO são apresentados na Tabela 12.

Tabela 12 - Parâmetros de sintonia da estrutura integrada MPC e RTO.

<b>Camada</b>	<b>Parâmetros</b>
Cálculo de alvos e RTO	$\mathbf{C}_y = \text{diag}([1;0]); \mathbf{C}_u = \text{diag}([0;5]); \mathbf{C}_e = \text{diag}([1e5;1e5])$ $\Delta t_{CA} = 30s; \Delta t_{RTO} = 900s$
MPC	$m = 3; \Delta \mathbf{u}_{\max} = [1kg / s; 5^\circ C]; \Delta t_{MPC} = 30s$ $\mathbf{Q}_y = \text{diag}([1;0]); \mathbf{Q}_u = \text{diag}([0;2])$ $\mathbf{R} = \text{diag}([1e2;1e2]); \mathbf{S}_y = \text{diag}([1e5;1e5])$

### **Cenário 1:** Alterações das condições de mercado.

Neste cenário foram realizadas alterações nas condições de mercado por meio das mudanças repentinas dos preços, que por sua vez alteram a função lucro otimizada pela RTO. As alterações foram realizadas para cada projeto seguindo a ordem apresentada na Tabela 13.

Tabela 13 - Alterações de mercado propostas no Cenário 1.

Projeto	Cenário de Mercado			
	Estado inicial	Primeira alteração	Segunda alteração	Terceira alteração
1	1	2	3	4
2	2	3	4	1
3	3	4	1	2
4	4	1	2	3

As Figuras 21 e 22 apresentam o comportamento das variáveis controladas para um horizonte de simulação de  $5h$ .

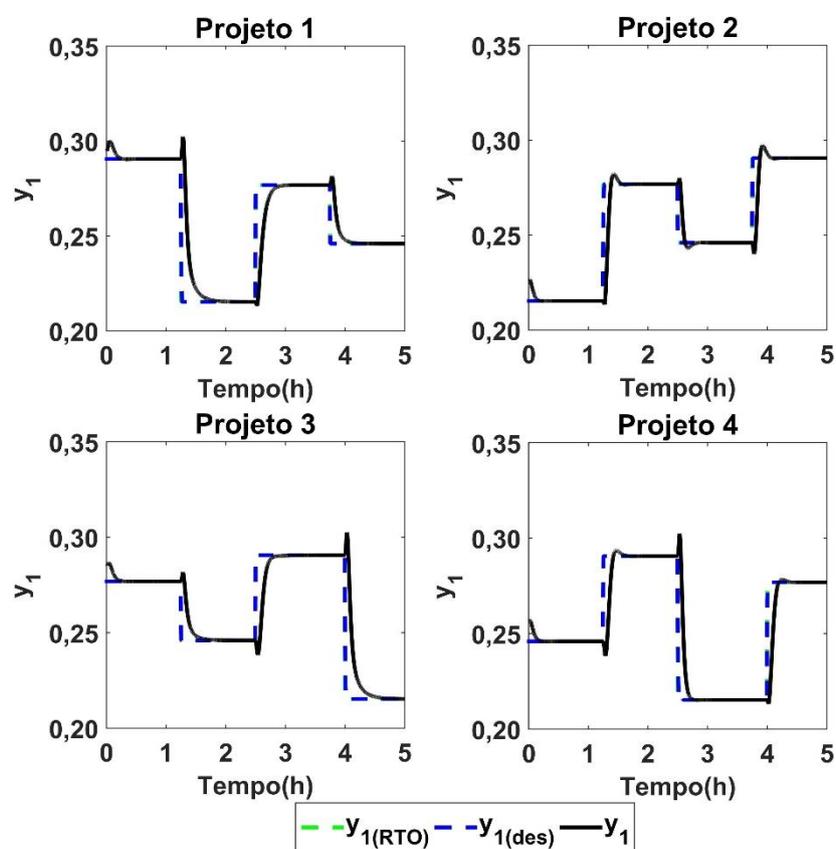


Figura 21 - Comportamento dinâmico da variável  $y_1$  para cada projeto (Cenário 1).

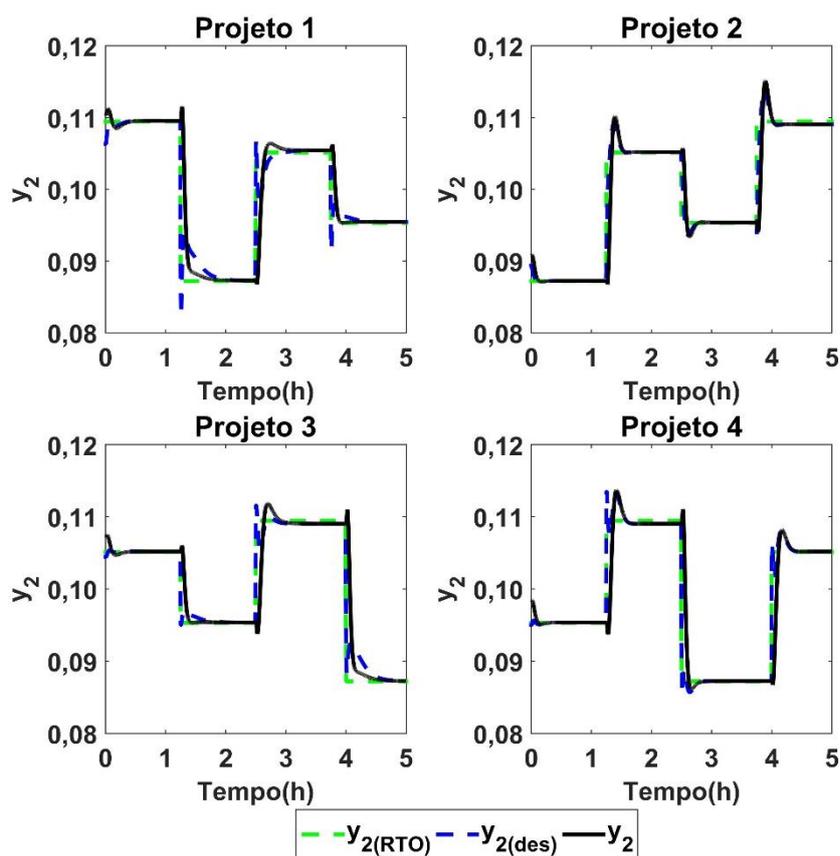


Figura 22 - Comportamento dinâmico da variável  $y_2$  para cada projeto (Cenário 1).

Embora apresentem diferentes retornos econômicos, todas as estruturas de controle para os diferentes projetos conseguem garantir as variáveis controladas sigam os valores calculados pela camada RTO, mesmo em um cenário de alterações nos preços dos produtos. Da mesma forma, podemos observar que a estrutura proposta em cada projeto consegue seguir com satisfação as condições ótimas da RTO para as variáveis manipuladas (Figura 23 e Figura 24).

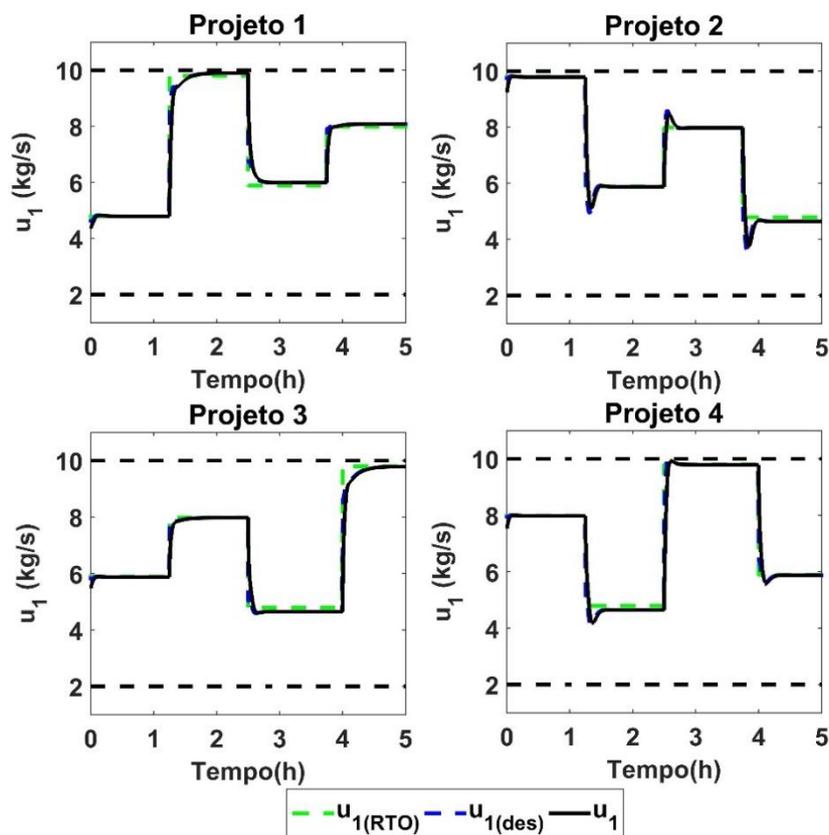


Figura 23 - Comportamento dinâmico da variável  $u_1$  para cada projeto (Cenário 1).

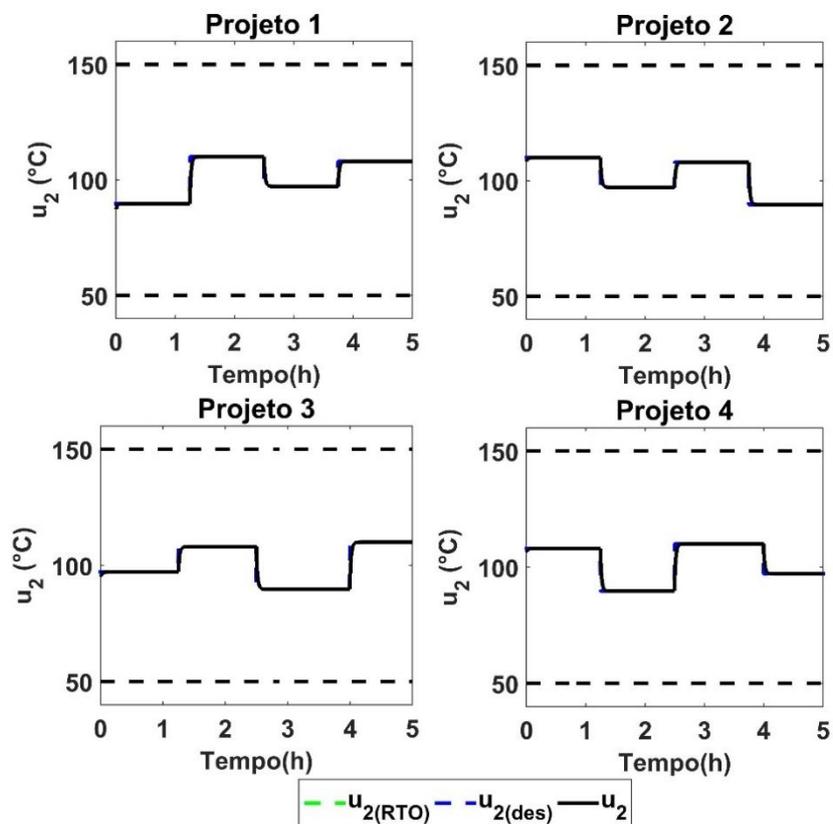


Figura 24 - Comportamento dinâmico da variável  $u_2$  para cada projeto (Cenário 1).

Quando a avaliação é realizada do ponto de vista econômico, através do cálculo do lucro obtido durante o tempo de simulação, é possível observar que o projeto econômico ótimo em estado estacionário com maior retorno financeiro (projeto 2) nem sempre apresenta o maior lucro em todas as faixas de operação (Figura 25). As alterações nos preços dos componentes da reação, em uma situação dinâmica, levam as condições econômicas ótimas do sistema a sofrerem mudanças. O processo é levado a produzir mais ou menos dos produtos desejados ou consumir menos dos reagentes da reação, buscando os maiores lucros de acordo com suas variáveis de projeto previamente definidas e a atuação do sistema de controle.

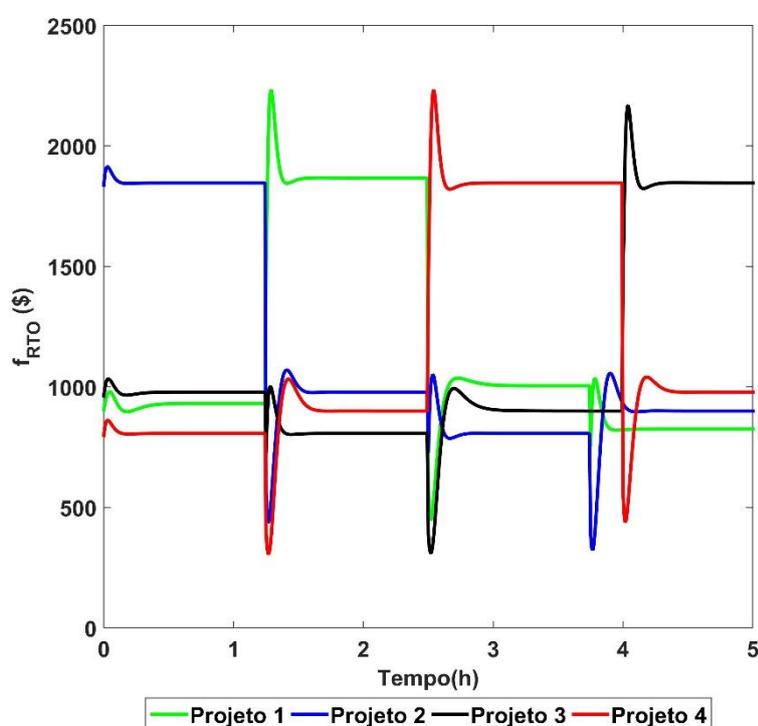


Figura 25 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 1).

Como o projeto em estado estacionário não considera alterações de mercado, mesmo aquele com melhor retorno anual, pode, em determinados cenários de operação, obter menores valores de lucro e não conduzem à uma operação dinâmica ótima do ponto de vista econômico, conforme apresentado na Tabela 14.

Tabela 14 - Somatório do lucro ao longo do tempo de simulação (Cenário 1).

Projeto ótimo na Condição	Somatório do lucro (\$)
1	6,93e5
2	6,77e5
3	6,52e5
4	7,02e5

Os resultados da tabela confirmam e apresentam, que, embora os projetos que representam as condições de mercado 1 e 4 tenham inicialmente percentuais de retorno menores, considerando o projeto em estado estacionário, tais projetos podem apresentar lucros melhores ao sistema em condições operacionais dinâmicas ocasionados por alterações nos preços e demandas de produtos, o que ocorre principalmente em um cenário global como estamos vivendo, impulsionado ainda mais pela pandemia que assola nossos dias há mais de um ano.

### Cenário 2: Rejeição de perturbações.

Neste cenário foram realizadas alterações nas variáveis de perturbação  $F_A$  e  $k_{20}$ , conforme apresentado na Figura 26.

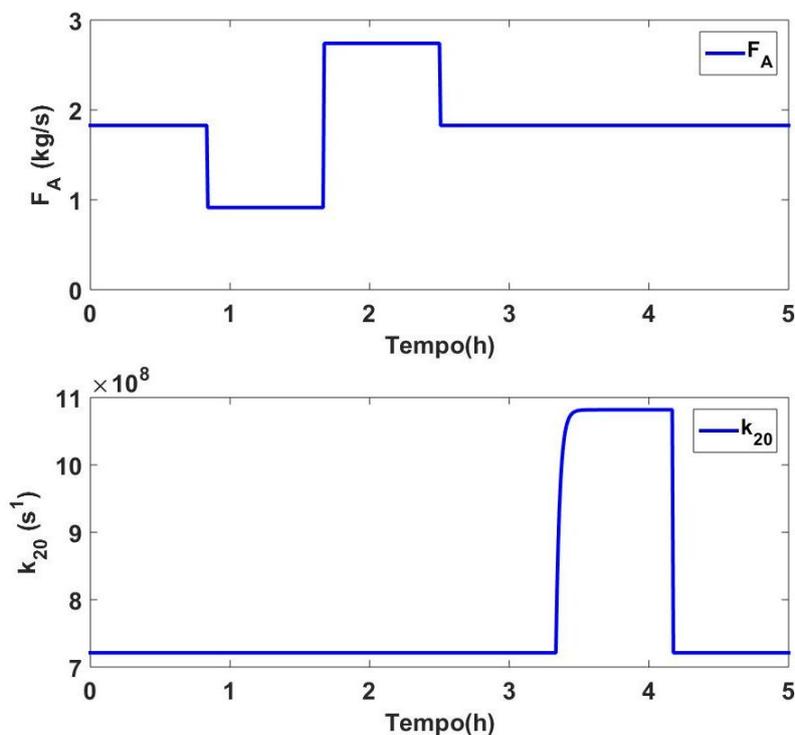


Figura 26 - Perturbações aplicadas ao sistema (Cenário 2).

As Figuras 27 e 28 apresentam o comportamento das variáveis controladas no cenário de rejeição das perturbações.

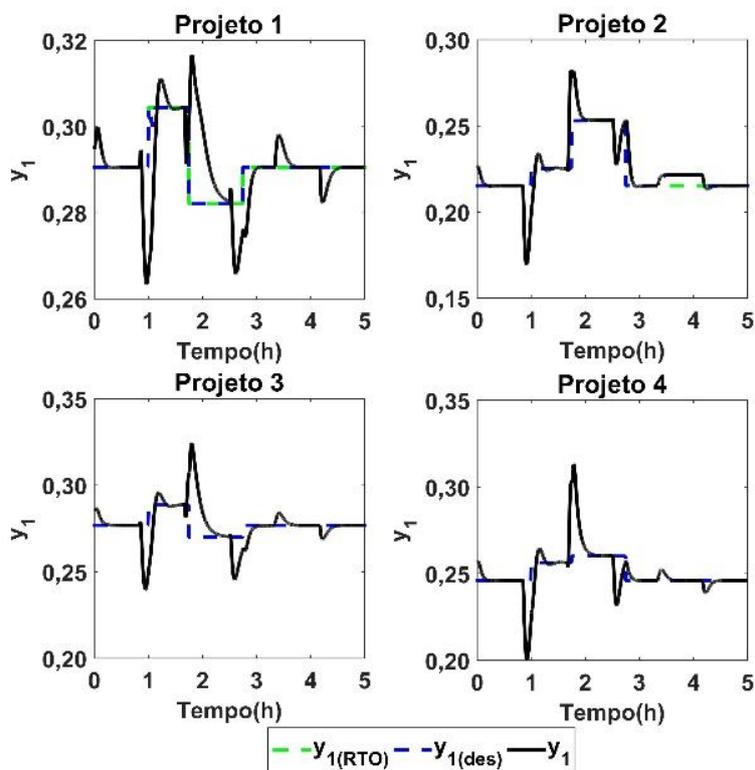


Figura 27 - Comportamento dinâmico da variável  $y_1$  para cada projeto (Cenário 2).

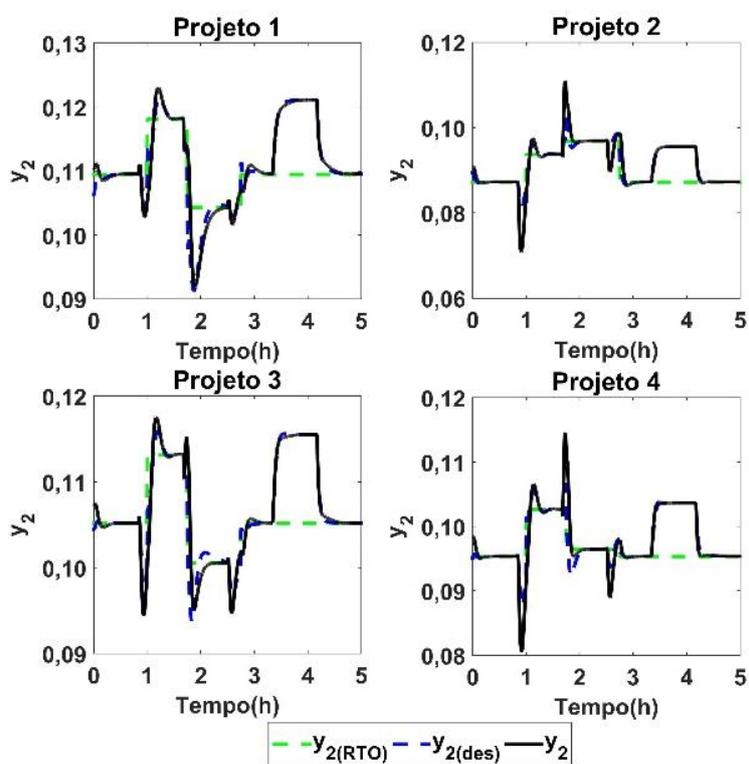


Figura 28 - Comportamento dinâmico da variável  $y_2$  para cada projeto (Cenário 2).

Diferentemente do que ocorre no cenário 1, os 4 projetos não conseguem acompanhar o ótimo econômico da variável  $y_2$  calculado pela RTO, quando ocorrem alterações na variável de perturbação não medida do sistema. Estas alterações, por sua vez, modificam os valores ótimos econômicos também das variáveis manipuladas, seguidas de perto pelos controladores. Dessa forma, é possível notar um bom desempenho dinâmico da operação com o controlador projetado, seguindo de maneira satisfatória os valores ótimos calculados pela RTO na maior parte do tempo. É possível observar, que para os projetos 1, 2 e 4 há saturação nos valores limites da variável  $u_1$  (Figura 29). Vale a pena ressaltar que a estrutura de controle por zona manteve os valores das variáveis dentro de seus limites operacionais em todo o horizonte de simulação.

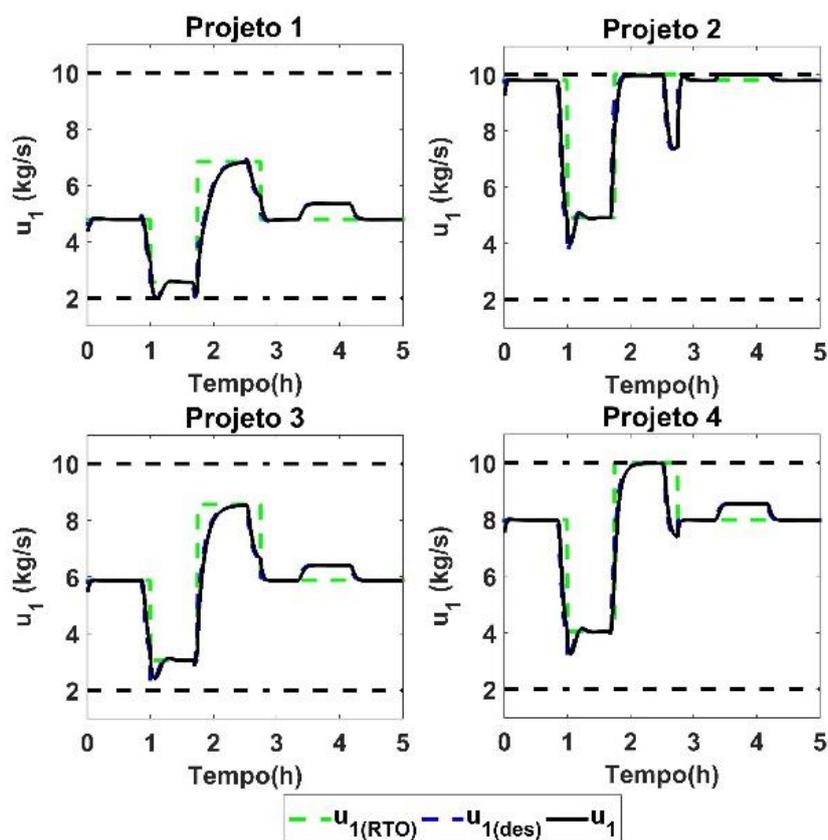


Figura 29 - Comportamento dinâmico da variável  $u_1$  para cada projeto (Cenário 2).

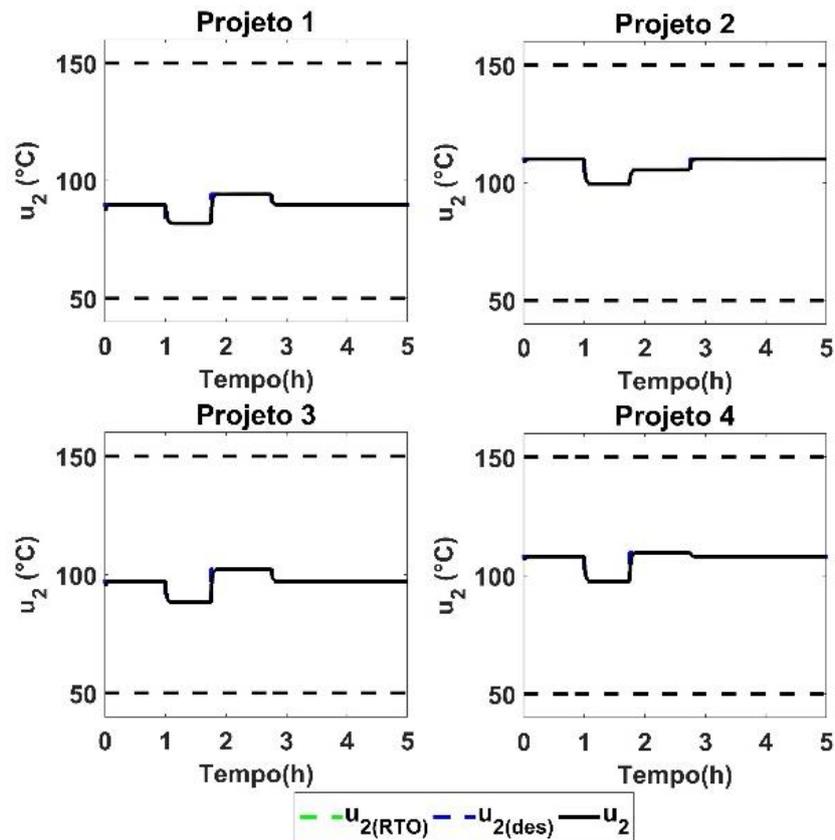


Figura 30 - Comportamento dinâmico da variável  $u_2$  para cada projeto (Cenário 2).

A análise financeira do problema para o cenário 2 foi conduzida, assim como para o cenário 1, e a Figura 31 apresenta o comportamento dinâmico da função de lucro.

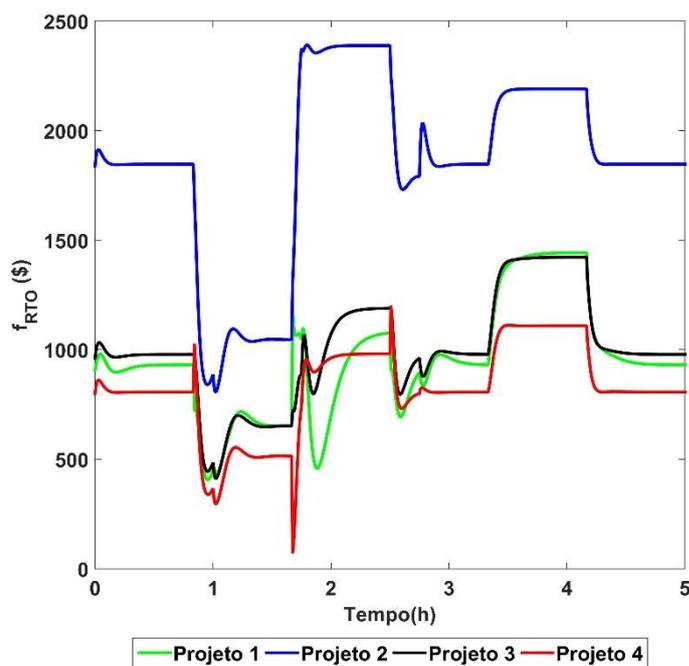


Figura 31 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 2).

Do ponto de vista econômico, é possível observar que o projeto 1, que teve maior valor de retorno econômico, obtido pela otimização em estado estacionário, confirmou durante maior parte da simulação um maior valor de lucro durante todo o tempo de simulação. Entretanto há variações entre aqueles que apresentam maiores lucros, dependendo da condição econômica ótima calculada pela RTO em virtude das alterações nas variáveis de perturbação. Além disso, vale a pena ressaltar que, embora o projeto em estado estacionário aponte o projeto 2 como aquele de maior retorno financeiro, uma análise dinâmica aponta que nem sempre essa afirmativa é observada. A Tabela 15 apresenta o somatório do lucro durante o tempo de simulação.

Tabela 15 - Somatório do lucro ao longo do tempo de simulação (Cenário 2).

<b>Projeto ótimo na Condição</b>	<b>Somatório do lucro (\$)</b>
1	5,71e5
2	7,89e4
3	5,17e5
4	3,07e5

Embora do ponto de vista dinâmico os controladores consigam manter os valores das variáveis o mais próximo possível dos valores econômicos desejados, os resultados confirmam limitações de uma abordagem tradicional de projeto de processos. Ao submeter o sistema a perturbações e alterações previstas em suas condições de mercado, foi possível notar que nem sempre aquela com melhores aspectos econômicos em estado estacionário obtém melhores índices em operação dinâmica. Os resultados, por sua vez, indicam a necessidade da aplicação de uma metodologia simultânea de projeto de processos e do sistema de controle, visando eliminar tais limitações. A metodologia consiste em adicionar aspectos da dinâmica do sistema na etapa de projetos e como visto anteriormente, traz melhorias à operação dinâmica e nos aspectos econômicos do sistema. Os aspectos econômicos são considerados através do cálculo da função de retorno de investimento, aspectos de planejamento, através das alterações nas condições de mercado e dinâmicas, em uma função suave que minimiza o erro entre os valores da RTO e a saída do controlador. A formulação final busca uma solução em que o

problema integrado ofereça melhores lucros, mesmo na presença de perturbações ou alterações de mercado e demanda.

### 6.3.2 Projeto simultâneo de processos e do sistema de controle usando a estrutura IHMPC e RTO considerando extensões adaptativas

Nesta etapa, realizou-se o projeto simultâneo com a estrutura de controle IHMPC e RTO considerando a atualização online dos parâmetros do modelo preditivo e a combinação linear de dois modelos (obtidos com a partir das regiões operacionais das condições de mercado 1 e 2) como extensões adaptativas. As Tabelas 16 e 17 apresentam os projetos simultâneos obtidos para as 2 propostas apresentadas na metodologia.

Tabela 16 - Resultados do projeto simultâneo do processo e seu sistema de controle usando a estrutura integrada de IHMPC e RTO com a extensão adaptativa online.

<b>Problema 2</b>			
<b>Variáveis</b>	<b>Unidades</b>	<b>Valores</b>	
$q_{y1}$	[-]	907,41	
$q_{y2}$	[-]	907,41	
$q_{u1}$	[-]	109,05	
$q_{u2}$	[-]	104,94	
$r_1$		2,06	
$r_2$		18,52	
$d = W$	[kg]	2002,06	
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[5,57; 94,65]	
$\phi_{din}^{Ut}$	[-]	0,0303	
<b>Problema 3</b>			
<b>Variáveis</b>	<b>Unidades</b>	<b>Valores ótimos</b>	
		<b>Método CQ</b>	<b>Método AM</b>
$q_{y1}$	[-]	907,41	907,40
$q_{y2}$	[-]	932,10	907,41
$q_{u1}$	[-]	104,94	107,11
$q_{u2}$	[-]	104,94	104,95
$r_1$		6,18	2,03
$r_2$		6,18	18,54
$d = W$	[kg]	2104,94	2002,26
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[5,60; 95,06]	[5,83; 95,56]
$\phi_{din}$	[-]	0,0358	0,0392
$[\phi_{eco}^1; \phi_{eco}^2]$	[%; %]	[7,36e5; 4,61e6]	[6,20e5; 4,72e6]

Tabela 17 - Resultados do projeto simultâneo do processo e seu sistema de controle usando a estrutura integrada de IHMPC e RTO com a extensão adaptativa de combinação linear.

<b>Problema 2</b>			
<b>Variáveis</b>	<b>Unidades</b>	<b>Valores ótimos</b>	
$q_{y1}$	[-]	969,14	
$q_{y2}$	[-]	804,53	
$q_{u1}$	[-]	2,06	
$q_{u2}$	[-]	24,01	
$r_1$		890,95	
$r_2$		6,17	
$d = W$	[kg]	2002,06	
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[5,56; 96,98]	
$\phi_{din}^{Ut}$	[-]	0,0590	
<b>Problema 3</b>			
<b>Variáveis</b>	<b>Unidades</b>	<b>Valores ótimos</b>	
		<b>Método CQ</b>	<b>Método AM</b>
$q_{y1}$	[-]	997,94	969,25
$q_{y2}$	[-]	779,84	804,52
$q_{u1}$	[-]	2,06	1,79
$q_{u2}$	[-]	36,35	23,86
$r_1$		303,30	890,97
$r_2$		0,69	3,33
$d = W$	[kg]	2221,54	2003,54
$\mathbf{u} = [F_B; T_R]$	[kg / s; °C]	[5,56; 94,51]	[6,14; 100,82]
$\phi_{din}$	[-]	0,0681	0,0748
$[\phi_{eco}^1; \phi_{eco}^2]$	[%; %]	[7,71e5; 4,43e6]	[4,50e5; 4,63e6]

### Cenário 1: Alterações das condições de mercado.

Neste cenário foram realizadas alterações nas condições de mercado por meio das mudanças repentinas dos preços, que por sua vez alteram a função lucro otimizada pela RTO. As alterações foram realizadas para cada projeto seguindo a ordem apresentada na Tabela 13. A Figura apresenta o comportamento das variáveis controladas para os projetos simultâneos.

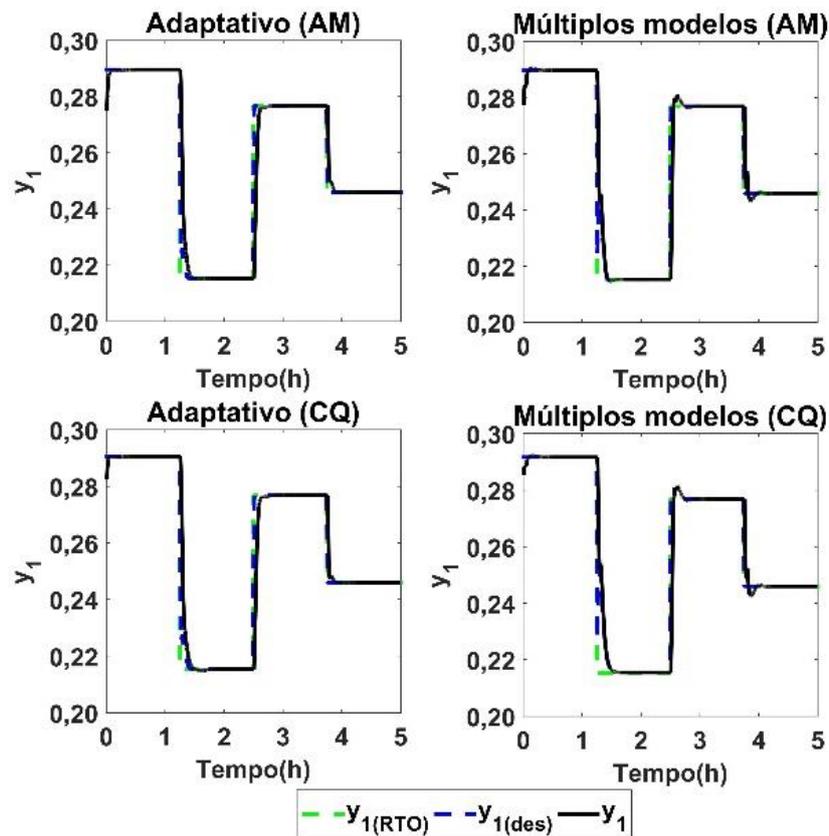


Figura 32 - Comportamento dinâmico da variável  $y_1$  para os projetos simultâneos (Cenário 1).

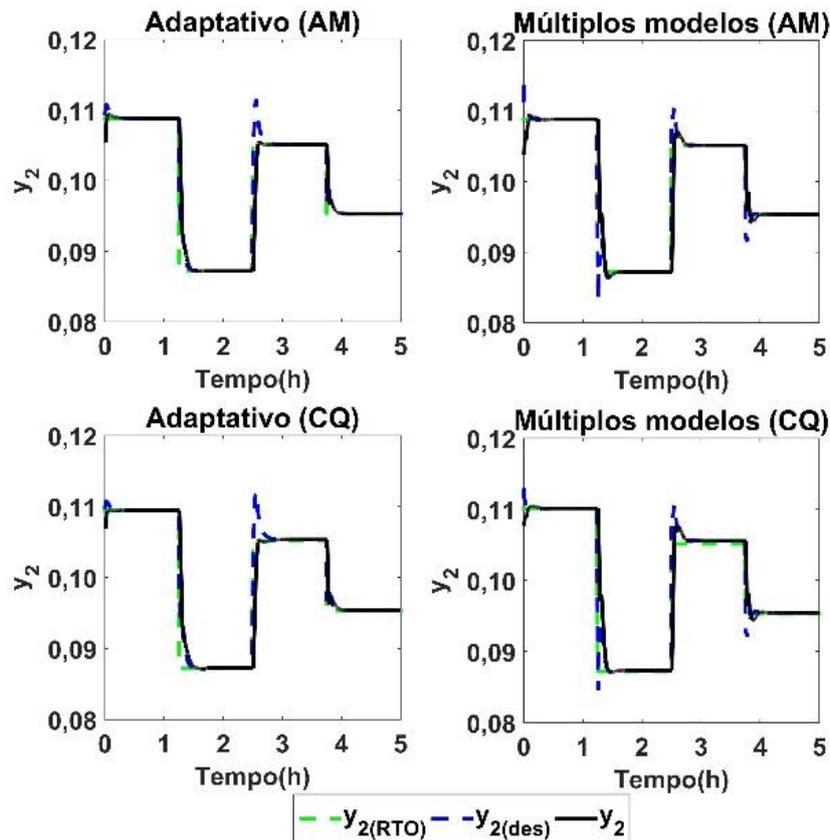


Figura 33 - Comportamento dinâmico da variável  $y_2$  para os projetos simultâneos (Cenário 1).

A otimização obteve projetos simultâneos do reator e do sistema de controle que foram capazes de seguir as mudanças nas condições ótimas em virtude das alterações nos preços dos produtos. É possível notar também que os controladores obtidos no projeto simultâneo alcançam de maneira mais rápida os novos *setpoints*, cumprindo o seu objetivo de alcançar melhorias dinâmicas no processo. Embora não seja um problema, vale a pena ressaltar que para atingir os estados ótimos calculados pela RTO, os valores da variável manipulada  $u_1$  saturaram na condição de mercado 2 (Figura 34), também pela proximidade da condição com o limite superior da variável (10 kg/s).

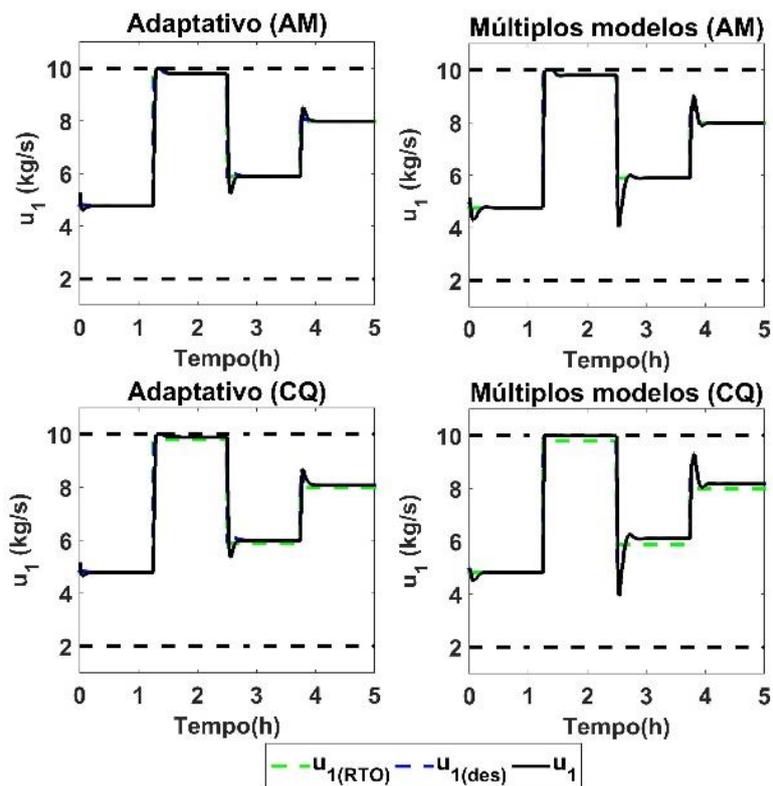


Figura 34 - Comportamento dinâmico da variável  $u_1$  para os projetos simultâneos (Cenário 1).

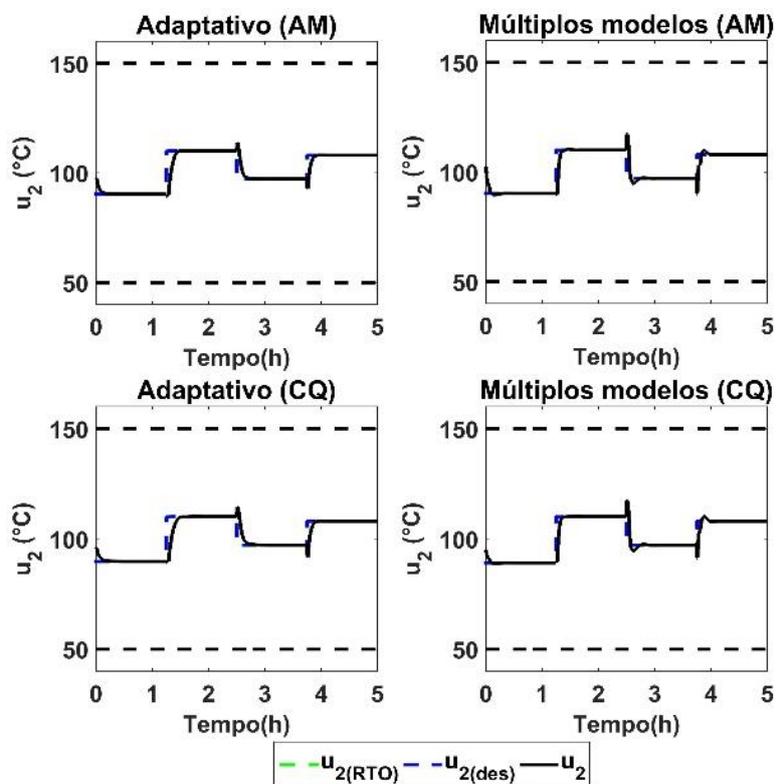


Figura 35 - Comportamento dinâmico da variável  $u_2$  para os projetos simultâneos (Cenário 1).

A avaliação econômica do ponto de vista dinâmico nos auxilia na observação da melhoria econômica do processo. Observa-se, que conforme as condições se alteram, os projetos que são mais lucrativos se revezam ao longo da operação dinâmica.

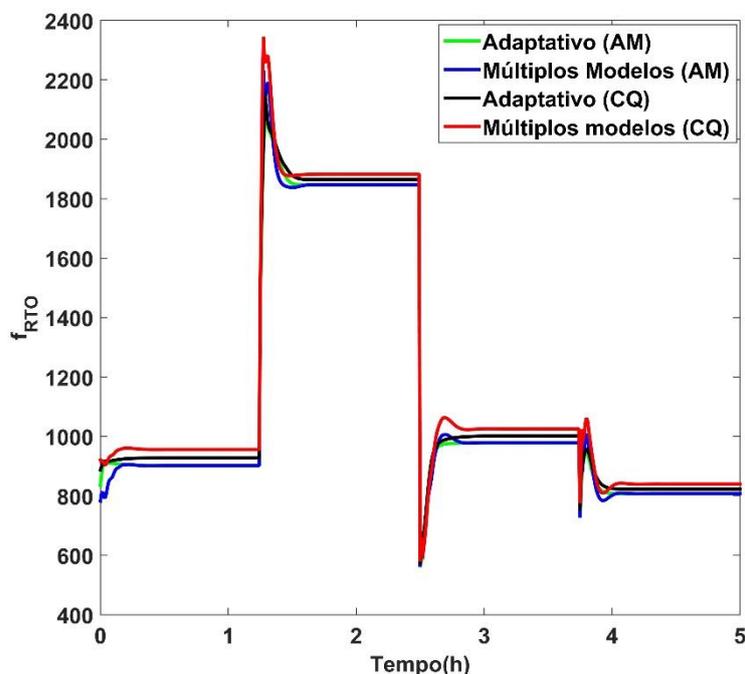


Figura 36 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 1).

Embora nem todos os projetos simultâneos foram capazes de oferecerem melhorias econômicas em comparação ao Projeto 4 apresentado anteriormente, é possível notar que há significativa melhora na lucratividade de operação em considerar esta metodologia. Os projetos obtidos pelo algoritmo alcance de metas obtiveram menores valores de lucro, que em contrapartida são maiores que aqueles obtidos pelos projetos 2 e 3 em estado estacionário (comparação entre a Tabela 14 e a Tabela 18). Os projetos simultâneos obtidos através da metodologia do custo quadrático obtiveram os melhores lucros e ultrapassaram os valores obtidos anteriormente, demonstrando a utilidade da metodologia de projetos simultâneos.

Tabela 18 - Somatório do lucro ao longo do tempo de simulação (Cenário 1).

Projeto simultâneo	Somatório do lucro (\$)
Adaptativo (AM)	6,82e5
Múltiplos modelos (AM)	6,81e5
Adaptativo (CQ)	6,94e5
Múltiplos modelos (CQ)	7,08e5

Os resultados da tabela confirmam e apresentam que a otimização de projetos simultâneos pode melhorar ainda mais os aspectos dinâmicos e econômicos também de uma estrutura de controle que integra um controlador preditivo com a camada RTO. Embora seja um valor de 0,85% de aumento do projeto simultâneo em comparação ao projeto 4 de estado estacionário, vale a pena destacar que o projeto simultâneo considerou apenas 2 condições de mercado e que provavelmente uma otimização que considera as 4 condições poderia aumentar a lucratividade da planta na operação dinâmica. Mesmo que na prática não seja possível de prever todas as condições, considerar 2, ainda que sejam poucas no universo de todas as possíveis, já garante lucro e melhorias dinâmicas no processo.

#### **Cenário 2:** Rejeição de perturbação.

O segundo cenário consistiu em avaliar a capacidade de rejeição das mesmas perturbações da Figura 26 utilizando os dois controladores obtidos pela metodologia de projeto simultâneo. É possível notar que embora os projetos consigam manter as variáveis controladas seguindo os valores ótimos econômicos da RTO para  $y_1$ , os controladores não conseguem rejeitar a perturbação não medida em  $k_{20}$ . Observa-se ainda que os controladores atualizados a cada instante de tempo não conseguem voltar para os valores desejados e se perdem na medida que saturam no limite inferior da variável manipulada  $u_1$  (Figura 39). Embora tenham usado um pequeno número de modelos, as estratégias adaptativas de modelos identificados em diferentes condições obtiveram ações de controle que puderam manter os valores mais próximos do ótimo econômico, seguindo o valor desejado enviado pela camada intermediária entre o MPC e a RTO.

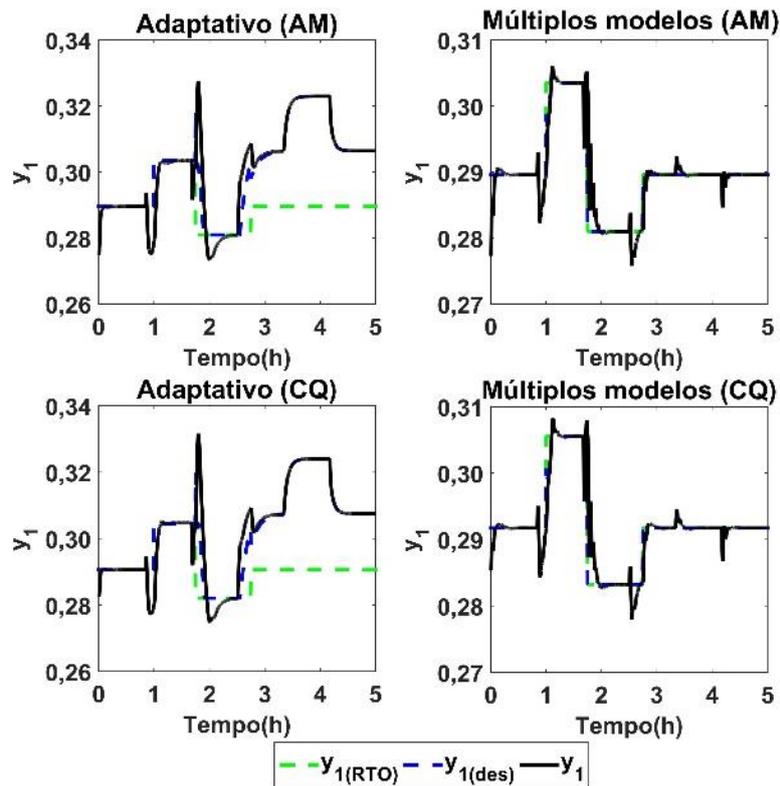


Figura 37 - Comportamento dinâmico da variável  $y_1$  para os projetos simultâneos (Cenário 2).

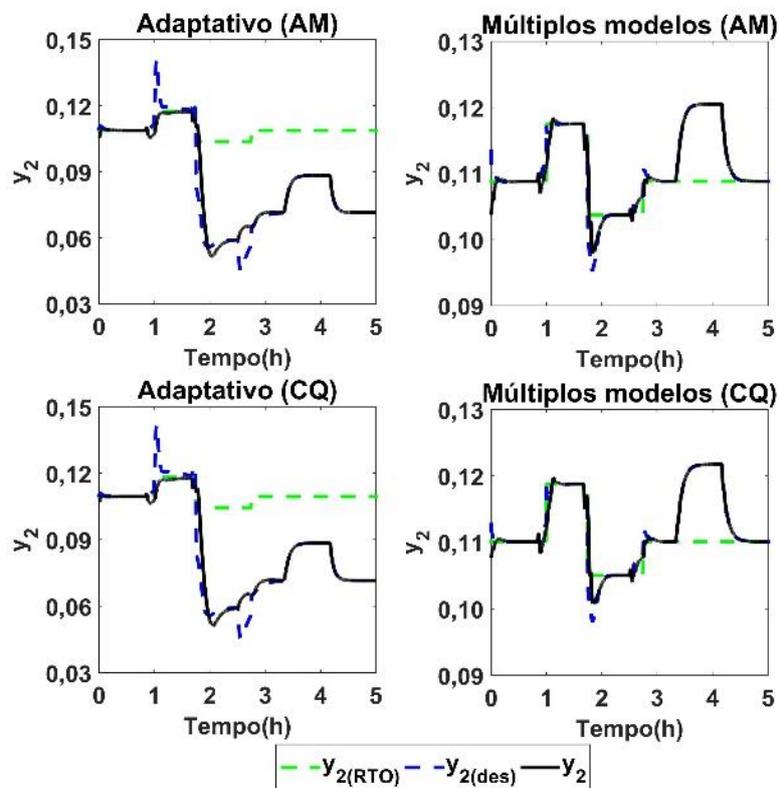


Figura 38 - Comportamento dinâmico da variável  $y_2$  para os projetos simultâneos (Cenário 2).

Como a RTO não recebe as informações dessa perturbação, ela não atualiza os seus valores ótimos econômicos, diferente do processo, que ao receber tais mudanças, altera sua condição. Isso pode ser notado quando avaliamos o gráfico a partir da terceira hora de operação. Nestes instantes, a camada de cálculo de alvos, baseada no modelo linear do processo envia alvos diferentes da condição ótima econômica. Uma possível resposta a esta dificuldade, mesmo para os projetos simultâneos, é a falta de um modelo de perturbação, que espera ser capaz de eliminar *offset* e a dificuldade de os controladores seguirem a RTO quando submetidos a perturbações não medidas, contribuindo para melhores lucros e menores erros na operação dinâmica. Entretanto, vale a pena ressaltar que na maior parte do tempo os alvos foram atingidos e os controladores mantiveram as variáveis dentro das restrições impostas pelo sistema.

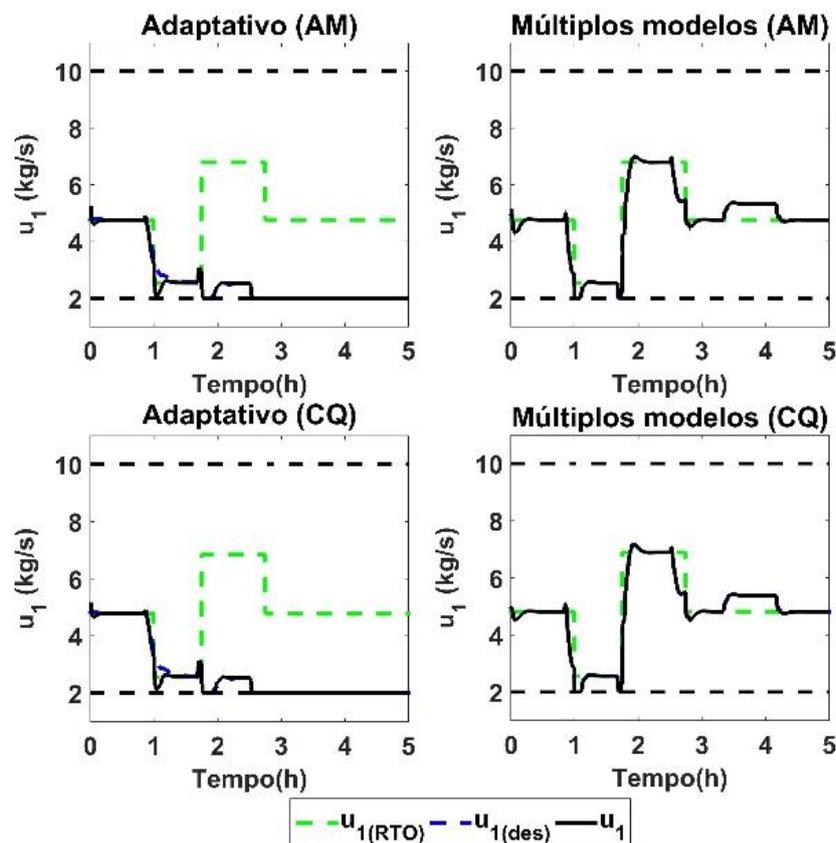


Figura 39 - Comportamento dinâmico da variável  $u_1$  para os projetos simultâneos (Cenário 2).

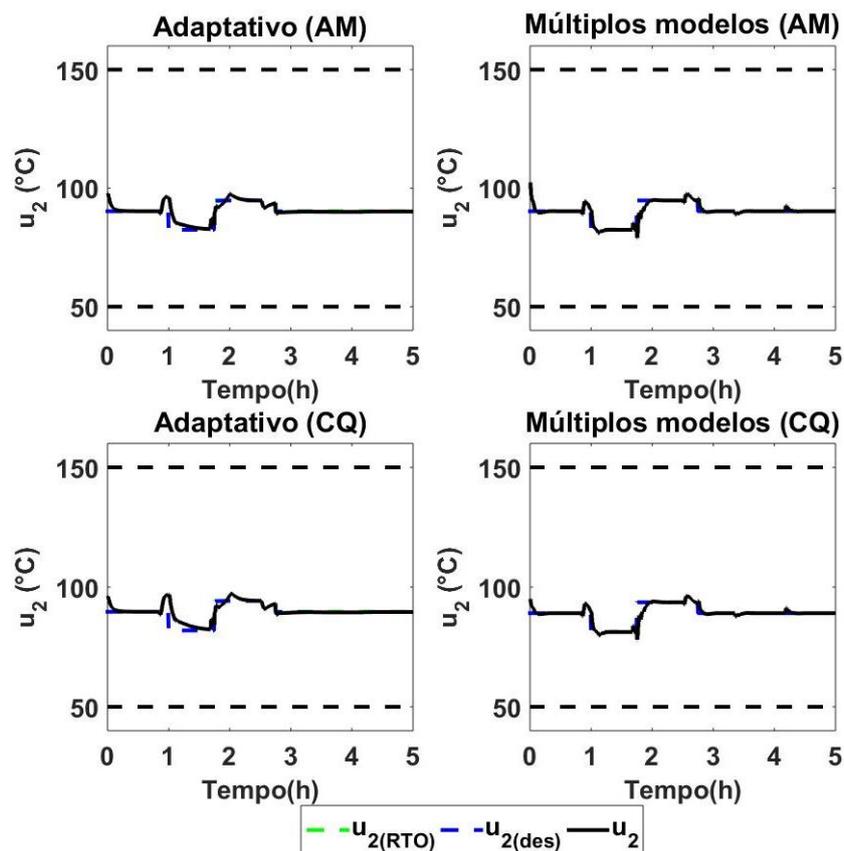


Figura 40 - Comportamento dinâmico da variável  $u_2$  para os projetos simultâneos (Cenário 2).

Do ponto de vista do retorno financeiro da operação dinâmica, é possível notar que além do projeto simultâneo conseguir seguir os alvos econômicos desejados, há também acréscimo de lucro no tempo total de operação para este caso (Tabela 19 e Figura 41). Assim, o projeto simultâneo cumpriu com o esperado e ofereceu plantas otimizadas em aspectos econômicos e dinâmicos, com melhorias de até 17%, ao comparar o projeto usando os múltiplos modelos e o algoritmo de alcance de metas com o projeto 1 obtido anteriormente.

Tabela 19 - Somatório do lucro ao longo do tempo de simulação (Cenário 2).

Projeto simultâneo	Somatório do lucro (\$)
Adaptativo (AM)	1,23e5
Múltiplos modelos (AM)	6,68e5
Adaptativo (CQ)	1,28e5
Múltiplos modelos (CQ)	6,02e5

A análise financeira também foi conduzida avaliando os lucros ao longo do tempo de simulação (Figura 41). É possível observar que apenas as

configurações obtidas com a estratégia de múltiplos modelos foram capazes de fornecer lucro durante todo horizonte de simulação do processo.

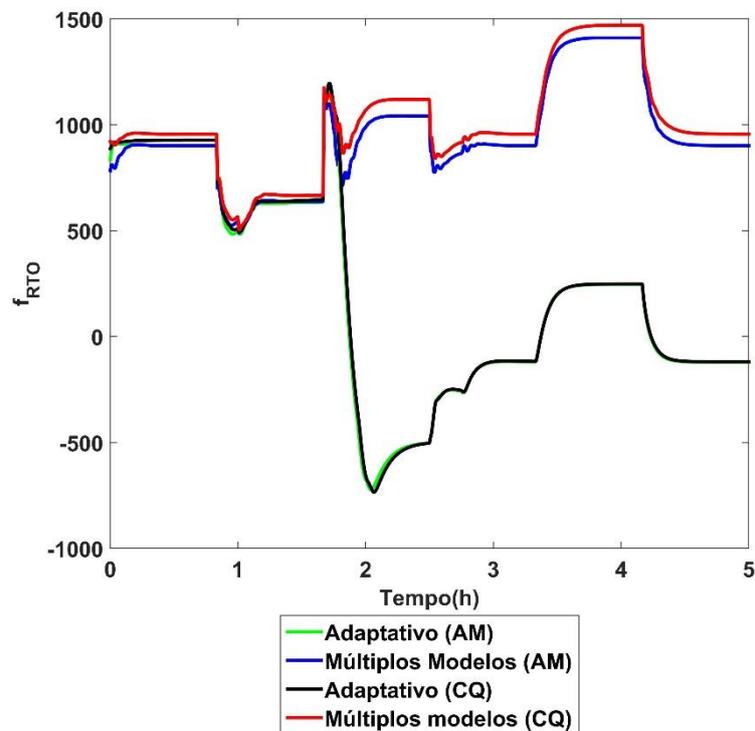


Figura 41 - Lucro obtido pela planta durante o horizonte de simulação (Cenário 2).

O prejuízo observado em grande parte das configurações obtidas através do modelo adaptativo atualizado em cada instante de tempo pode ser explicado pela saturação no limite inferior de  $u_1$ , que por sua vez acarreta menor produção do produto  $y_2$ . O prejuízo só não foi maior devido à RTO, que calcula ótimos econômicos e acarreta e maior lucratividade da planta.

## 7 CONCLUSÕES

Neste estudo, uma nova metodologia simultânea de projeto de processos e de seu sistema de controle foi desenvolvida. Usando algoritmos de programação não linear, o problema simultâneo foi dividido em três etapas. A abordagem foi testada em um modelo do reator de Williams-Otto, que é conhecido por demonstrar características de processos reais, como não linearidades, resposta inversa e inversão de ganho.

A primeira etapa consistiu em otimizar a melhor configuração do reator em estado estacionário, baseada em aspectos puramente econômicos. Duas condições de mercado diferentes foram utilizadas pela metodologia, determinadas pela variação de preço dos componentes da reação. A função econômica buscou maximizar o retorno perante o investimento inicial da planta. Com base nessas premissas, duas regiões viáveis diferentes foram obtidas, uma para cada condição de mercado. Na segunda etapa, essas condições distintas foram usadas como valores desejados para um problema de flexibilidade, que avaliou a capacidade do processo em transitar de forma suave e eficaz por diferentes regiões de operação do sistema. Assim, foi possível também oferecer à metodologia aspectos de planejamento. Para quantificar o problema de flexibilidade, a integral do erro quadrático foi utilizada como função objetivo a ser minimizada no problema de otimização com aspecto puramente dinâmico.

Por fim, na última etapa, pretendeu-se atingir os objetivos obtidos nos dois primeiros problemas simultaneamente. Duas abordagens foram propostas para resolver o problema de otimização: a técnica de alcance de metas e a formulação da função objetivo na forma quadrática. Em ambas, os objetivos de otimização foram os objetivos calculados nos problemas anteriores, definidos como objetivos utópicos. Os projetos simultâneos obtidos foram comparados com uma abordagem de projeto sequencial e com uma sintonia padrão para o controlador normalizado. Os resultados mostraram que a metodologia proposta apresentou excelente desempenho em comparação com as duas configurações sequenciais, com lucros obtidos maiores e valores de erro menores para cenários de simulação nos quais foram considerados problemas servo e regulatório. Além disso, vale ressaltar que devido às limitações apresentadas

nas abordagens sequenciais, seja a otimizada ou a sintonia padrão, uma das variáveis manipuladas ficou saturada no limite inferior em determinadas condições de operação. Assim, apenas as configurações simultâneas tiveram sucesso em manter a variável controlada próxima aos seus valores desejados.

Embora os resultados iniciais apresentem a metodologia como bem-sucedida em fornecer um projeto simultâneo ideal para o reator de Williams-Otto, este trabalho buscou apresentar ainda solução concentrada em dois aspectos para análise posterior. O primeiro, consistiu em aprimorar a implementação da estratégia de controle para incorporar incertezas no modelo a evitar a má combinação das condições de linearização com as variáveis de projeto, introduzindo a mudança das variáveis de projeto na dinâmica do controlador MPC, utilizando um controlador adaptativo para o qual os parâmetros do modelo são atualizados de forma online. A abordagem adaptativa foi comparada com a primeira obtida em um cenário de perturbação aleatória na vazão do reagente  $F_A$ . Tal condição pode ser ocasionada por um erro do operador ou falha mecânica, alterando as condições da alimentação do reator. O sistema de controle, por sua vez, deve ser capaz de lidar com essas situações, mantendo o processo nos valores desejados. A melhoria proposta com a estratégia adaptativa foi capaz de manter as frações do produto  $P$  e  $E$  próximas aos valores desejados, mesmo diante das perturbações, durante todo tempo de simulação. Tal observação é de extrema importância ao avaliar um processo não linear e instável, ao sofrer alterações em variáveis que causam alternâncias de comportamento e região de operação.

A terceira parte do trabalho busca atender o segundo aspecto e responder a questão relacionada aos desafios atuais, considerando uma estrutura hierárquica que integra o controlador IHMPC com uma camada RTO. A metodologia simultânea proposta neste trabalho, que considera também aspectos de planejamento e incorporação das variáveis de projeto na dinâmica dos modelos lineares foi apresentada como alternativa para levar em conta as incertezas do modelo e melhorar o desempenho dinâmico na presença de perturbações. Nesta abordagem adaptativa, o controlador é linearizado por expansão em série de Taylor, a partir do modelo não linear do processo e atualizado a cada instante de tempo, de forma a reduzir as limitações impostas

pelas aproximações dinâmicas do controlador MPC nominal, mantendo a convexidade do problema e fornecendo uma solução com menos complexidade computacional. Essa abordagem é comparada com uma alternativa em que modelos das duas condições usadas para calcular a trajetória do problema de otimização 2 fornecem a ação de controle ótima ao processo por uma combinação linear de ambas obtidas com cada modelo.

Os resultados apresentaram que mesmo em uma situação em que perturbações não medidas são consideradas, a metodologia simultânea oferece incrementos do ponto de vista de operação dinâmica e aspectos econômicos da planta (operações dinâmicas mais lucrativas). É possível notar que, embora uma estratégia adaptativa tenha oferecido também melhorias do ponto de vista econômico, nem sempre ela oferecerá melhorias dinâmicas em processos ruidosos (por amplificar o ruído) ou em processos com perturbações não medidas. Nestes casos, soluções em que o modelo atualiza não a cada instante de tempo, mas sim diante de determinada variação das condições operacionais e modelos considerando a perturbação podem ser alternativas para corrigir estes problemas. Dessa forma, as seguintes sugestões podem ser consideradas para trabalhos futuros:

- Avaliação da metodologia SPDC proposta neste trabalho para sistemas maiores e mais complexos, com várias unidades em que possivelmente apareçam também variáveis discretas;
- Alternativas adaptativas que não mais atualizam o modelo a cada instante de tempo, mas conforme uma determinada variação em seus estados de acordo com uma percentagem predeterminada;
- Avaliar também outras condições de mercado no problema de otimização simultânea, aumentando as opções de configurações de mercado do sistema, buscando melhores lucros e operação dinâmica;
- Avaliar outros modelos para a configuração de múltiplos modelos do sistema;
- Avaliar a inserção de um modelo não linear de predição para o controlador MPC.

## 8 REFERÊNCIAS

A. RODRIGUES, M.; ODLOAK, D. MPC for stable linear systems with model uncertainty. **Automatica**, v. 39, n. 4, p. 569–583, 2003.

ADETOLA, V.; GUAY, M. Robust Adaptive MPC for Systems with Exogeneous Disturbances. **IFAC Proceedings Volumes**, v. 42, n. 11, p. 249-254, 2009.

ALVAREZ, A. L. T. **Strategies with guarantee of stability for the integration of Model Predictive Control and Real Time Optimization**. São Paulo: Escola Politécnica, Universidade de São Paulo, 2012, 174 p. Tese (Doutorado).

ALVAREZ, L. A.; ODLOAK, D. Robust integration of real time optimization with linear model predictive control. **Computers and Chemical Engineering**, v. 34, n. 12, p. 1937–1944, 2010.

ALVAREZ, L. A.; ODLOAK, D. Optimization and control of a continuous polymerization reactor. **Brazilian Journal of Chemical Engineering**, v. 29, n. 4, p. 807–820, 2012.

AMRIT, R. **Optimizing process economics in model predictive control**. Wisconsin: University of Wisconsin-Madison, 2011, 193 p. Tese (Doutorado).

AMRIT, R.; RAWLINGS, J. B.; BIEGLER, L. T. Optimizing process economics online using model predictive control. **Computers and Chemical Engineering**, v. 58, p. 334–343, 2013.

ANEESH, V.; PARAMASIVAN, G.; SELVARAJU, N. Distillation technology and need of simultaneous design and control: A review. **Chemical Engineering and Processing: Process Intensification**, v. 104, p. 219–242, 2016.

ASTEASUAIN, M.; BRANDOLIN, A.; SARMORIA, C.; BANDONI, A. Simultaneous design and control of a semibatch styrene polymerization reactor. **Industrial and Engineering Chemistry Research**, v. 43, n. 17, p. 5233–5247, 2004.

ASTEASUAIN, M.; BANDONI, A.; SARMORIA, C.; BRANDOLIN, A. Simultaneous process and control system design for grade transition in styrene polymerization. **Chemical Engineering Science**, v. 61, n. 10, p. 3362–3378, 2006.

BAHAKIM, S. S.; RICARDEZ-SANDOVAL, L. A. Simultaneous design and MPC-based control for dynamic systems under uncertainty: A stochastic approach. **Computers and Chemical Engineering**, v. 63, n. 17, p. 66–81, 2014.

BAHRI, P. A.; BANDONI, J. A.; ROMAGNOLI, J. A. Integrated Flexibility and Controllability Analysis in Design of Chemical Processes. **AIChE Journal**, v. 43, n. 4, p. 997–1015, 1997.

BANSAL, V.; SAKIZLIS, V.; ROSS, R.; PERKINS, J. D.; PISTIKOPOULOS, E. N. New algorithms for mixed-integer dynamic optimization. **Computers and Chemical Engineering**, v. 27, p. 647–668, 2003.

BERNAL, D. E.; CARRILLO-DIAZ, C.; GÓMEZ, J. M.; RICARDEZ-SANDOVAL, L. A. Simultaneous design and control of catalytic distillation columns using comprehensive rigorous dynamic models. **Industrial and Engineering Chemistry Research**, v. 57, n. 7, p. 2587–2608, 2018.

BLANCO, A. M.; BANDONI, J. A. Interaction between process design and process operability of chemical processes: An eigenvalue optimization approach. **Computers and Chemical Engineering**, v. 27, n. 8, p. 1291–1301, 2003.

BRENGEL, D. D.; SEIDER, W. D. Coordinated design and control optimization of nonlinear processes. **Computers & Chemical Engineering**, v. 16, n. 9, p. 861–886, 1992.

BURNAK, B.; DIANGELAKIS, N. A.; KATZ, J. PISTIKOPOULOS, E. N. Integrated process design , scheduling , and control using multiparametric programming. **Computers and Chemical Engineering**, v. 125, p. 164–184, 2019.

CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. Londres: Springer-Verlag London, 2007, 405 p.

CARDOSO, A. O. **Otimização Descentralizada Coordenada aliada a**

**estratégias de Controle Plantwide para o Controle de Processos Químicos.** São Carlos: Centro de Ciências Exatas e Tecnologia, Universidade Federal de São Carlos, 2016. 153 p. Tese (Doutorado).

CARRAPIÇO, O. L.; SANTOS, M. M.; ZANIN, A. C.; ODLOAK, D. Application of the IHMPC to an industrial process system. **IFAC Proceedings Volumes**, v. 42, n. 11, p. 851–856, 2009.

CARRAPIÇO, O. L.; ODLOAK, D. A stable model predictive control for integrating processes. **Computers and Chemical Engineering**, v. 29, n. 5, p. 1089–1099, 2005.

CHAN, L. L. T.; CHEN, J. Probabilistic uncertainty based simultaneous process design and control with iterative expected improvement model. **Computers and Chemical Engineering**, v. 106, p. 609–620, 2017.

CHAWANKUL, N.; BUDMAN, H.; DOUGLAS, P. L. Integration of Design and Control: A Robust Control Approach Using MPC. **Canadian Journal of Chemical Engineering**, v. 85, n. 4, p. 433–446, 2007.

CUBILLOS, F. A.; ACUÑA, G.; LIMA, E. L. Real-time process optimization based on grey-box neural models. **Brazilian Journal of Chemical Engineering**, v. 24, n. 3, p. 433–443, 2007.

DAVID, I.; BOGLE, L.; MA, K.; HAGEMANN, J.; FRAGA, E. S. Analysing the controllability of nonlinear process systems. **Computer Aided Chemical Engineering**, v. 17, p. 168–186, 2004.

DE LA FUENTE, R. L. N.; FLORES-TLACUAHUAC, A. Integrated design and control using a simultaneous mixed-integer dynamic optimization approach. **Industrial and Engineering Chemistry Research**, v. 48, n. 4, p. 1933–1943, 2009.

DE OLIVEIRA, R. C.; DE CARVALHO, R. F.; ALVAREZ, L. A. Multi-model adaptive integration of real time optimization and model predictive control. **IFAC-PapersOnLine**, v. 52, n. 1, p. 661–666, 2019.

DE PRADA, C.; SARABIA, D.; GUTIERREZ, G.; GOMEZ, E.; MARMOL, S.; SOLA, M.; PASCUAL, C.; GONZALEZ, R. Integration of RTO and MPC in the hydrogen network of a petrol refinery. **Processes**, v. 5, n. 1, p. 1–20, 2017.

DE SOUZA, G.; ODLOAK, D.; ZANIN, A. C. Real time optimization (RTO) with model predictive control (MPC). **Computers and Chemical Engineering**, v. 34, n. 12, p. 1999–2006, 2010.

DIANGELAKIS, N. A.; BURNAK, B.; KATZ, J.; PISTIKOPOULOS, E. N. Process design and control optimization: A simultaneous approach by multi-parametric programming. **AIChE Journal**, v. 63, n. 11, p. 4827–4846, 2017.

DIANGELAKIS, N. A.; MANTHANWAR, A. M.; PISTIKOPOULOS, E. N. A Framework for Design and Control Optimisation : Application on a CHP System. **Computer Aided Chemical Engineering**, v. 34, p. 765-770, 2014.

DUTRA, J. C. S. **Controle de processos baseados em esquemas de reconfiguração**. Rio de Janeiro: COPPE, Universidade Federal do Rio de Janeiro, 2012. 193 p. Tese (Doutorado).

EDGAR, T. F. Control and operations: When does controllability equal profitability? **Computers and Chemical Engineering**, v. 29, n. 1, p. 41–49, 2004.

FERRAMOSCA, A.; GONZÁLEZ, A. H.; LIMON, D. Offset-free multi-model economic model predictive control for changing economic criterion. **Journal of Process Control**, v. 54, p. 1–13, 2017.

FINKEL, D. **DIRECT Optimization Algorithm User Guide**. Raleigh: North Carolina State University, 2003. 14 p. Guia de usuário.

FLORES-TLACUAHUAC, A.; GROSSMANN, I. E. Simultaneous scheduling and control of multiproduct continuous parallel lines. **Industrial and Engineering Chemistry Research**, v. 49, n. 17, p. 7909–7921, 2010.

FRANCISCO, M.; REVOLLAR, S.; VEGA, P.; LAMANNA, R. Simultaneous synthesis, design and control of processes using model predictive control. **IFAC Proceedings Volumes**, v. 42, n. 11, p. 863–868, 2009.

FRANCISCO, M.; VEGA, P. Diseño integrado de procesos de depuración de aguas utilizando control predictivo basado en modelos. **Revista Iberoamericana de automática e informática industrial ( RIAI )**, v. 3, n. 4, p. 88–98, 2006.

FRANCISCO, M.; VEGA, P.; ÁLVAREZ, H. Robust Integrated Design of processes with terminal penalty model predictive controllers. **Chemical Engineering Research and Design**, v. 89, n. 7, p. 1011–1024, 2011.

GEMBICKI, F.; HAIMES, Y. Approach to Performance and Sensitivity Multiobjective Optimization. **IEEE Transactions on Automatic Control**, v. 20, n. 6, p. 769–771, 1975.

GONZÁLEZ, A. H.; ODLOAK, D. A stable MPC with zone control. **Journal of Process Control**, v. 19, n. 1, p. 110–122, 2009.

GUTIERREZ, G.; RICARDEZ-SANDOVAL, L. A.; BUDMAN, H.; PRADA, C. An MPC-based control structure selection approach for simultaneous process and control design. **Computers and Chemical Engineering**, v. 70, p. 11–21, 2014.

HULTGREN, M.; IKONEN, E.; KOVÁCS, J. Integrated control and process design for improved load changes in fluidized bed boiler steam path. **Chemical Engineering Science**, v. 199, p. 164–178, 2019.

HUUSOM, J. K. Challenges and opportunities in integration of design and control. **Computers and Chemical Engineering**, v. 81, p. 138–146, 2015.

KOLLER, R. W.; RICARDEZ-SANDOVAL, L. A. A dynamic optimization framework for integration of design, control and scheduling of multi-product chemical processes under disturbance and uncertainty. **Computers and Chemical Engineering**, v. 106, p. 147–159, 2017.

KYRIAKIDES, A. S.; VOUTETAKIS, S.; PAPADOPOULOU, S.; SAFERLIS, P. Integrated design and control of various hydrogen production flowsheet configurations via membrane based methane steam reforming. **Membranes**, v. 9, n. 1, p. 2019.

LENHOFF, A. M.; MORARI, M. Design of resilient processing plants - I. Process Design Under Consideration of Dynamic Aspects. **Chemical Engineering**

**Science**, v. 37, n. 2, p. 245–258, 1982.

LOEBLEIN, C.; PERKINS, J. D. Structural design for on-line process optimization: I. Dynamic economics of MPC. **AIChE Journal**, v. 45, n. 5, p. 1018–1029, 1999.

LUYBEN, M. L.; FLOUDAS, C. A. Analyzing the interaction of design and control-1. A multiobjective framework and application to binary distillation synthesis. **Computers and Chemical Engineering**, v. 18, n. 10, p. 933–969, 1994.

LUYBEN, W. L. **Process Modeling, Simulation, and Control for Chemical Engineers**. Michigan: McGraw-Hill, 1996. 725 p.

LUYBEN, W. L. The need for simultaneous design education. **Computer Aided Chemical Engineering**, v. 17, p. 10-41, 2004.

MACIEJOWSKI, J. M. **Predictive Control with Constraints**. New Jersey: Prentice H, 2002. 256 p.

MALCOLM, A.; POLAN, J.; ZHANG, L.; OGUNNAIKE, B. A.; LININGER, A. A. Integrating systems design and control using dynamic flexibility analysis. **AIChE Journal**, v. 53, n. 8, p. 2048–2061, 2007.

MANSOURI, S. S. **Integrated Process Design, Control and Analysis of Intensified Chemical Processes**. Kongens Lyngby: Technical University of Denmark, 2016. 147 p. Tese (Doutorado).

MANSOURI, S. S.; SALES-CRUZ, M.; HUUSOM, J. K.; GANI, R. Systematic integrated process design and control of reactive distillation processes involving multi-elements. **Chemical Engineering Research and Design**, v. 115, p. 348–364, 2016.

MARLER, R. T.; ARORA, J. S. The weighted sum method for multi-objective optimization: New insights. **Structural and Multidisciplinary Optimization**, v. 41, n. 6, p. 853–862, 2010.

MEHTA, S.; RICARDEZ-SANDOVAL, L. A. Integration of Design and Control of Dynamic Systems under Uncertainty : A New Back-Off Approach. **Industrial & Engineering Chemical Research**, v. 55, n. 2, p. 485-498, 2016.

MOHIDEEN, M. J.; PERKINS, J. D.; PISTIKOPOULOS, E. N. Optimal design of dynamic systems under uncertainty. **AIChE Journal**, v. 42, n. 8, p. 2251–2272, 1996.

MÖNNIGMANN, M.; MARQUARDT, W. Steady-state process optimization with guaranteed robust stability and flexibility: Application to HDA reaction section. **Industrial and Engineering Chemistry Research**, v. 44, n. 8, p. 2737–2753, 2005.

MOON, J.; KIM, S.; LINNINGER, A. A. Embedded control for optimizing flexible dynamic process performance. **Industrial and Engineering Chemistry Research**, v. 50, n. 9, p. 4993–5004, 2011a.

MOON, J.; KIM, S.; LINNINGER, A. A. Integrated design and control under uncertainty: Embedded control optimization for plantwide processes. **Computers and Chemical Engineering**, v. 35, n. 9, p. 1718–1724, 2011b.

MORARI, M. Design of resilient processing plants-III. A general framework for the assessment of dynamic resilience. **Chemical Engineering Science**, v. 38, n. 11, p. 1881–1891, 1983.

NANDOLA, N. N.; BHARTIYA, S. A multiple model approach for predictive control of nonlinear hybrid systems. **Journal of Process Control**, v. 18, n. 2, p. 131–148, 2008.

ODLOAK, D. Extended robust model predictive control. **AIChE Journal**, v. 50, n. 8, p. 1824–1836, 2004.

OGATA, K. **Engenharia de Controle Moderno**. São Paulo: Pearson Prentice Hall, 2010, 824 p.

OGUNNAIKE, B. A.; RAY, H. W. **Process Dynamic, Modeling, and Control**. New York: Oxford University Press, 1994, 1296 p.

PALAZOGLU, A.; ARKUN, Y. A multiobjective approach to design chemical plants with robust dynamic operability characteristics. **Computers & Chemical Engineering**, v. 10, n. 6, p. 567–575, 1986.

PALMA-FLORES, O.; RAFIEI, M.; RICARDEZ-SANDOVAL, L. A. On the implementation of nonlinear model predictive control for simultaneous design and control using a back-off approach. **IFAC-PapersOnLine**, v. 53, n. 2, p. 11551–11556, 2020.

PANJWANI, P.; SCHENK, M.; GEORGIADIS, M. C.; PISTIKOPOULOS, E. N. Optimal design and control of a reactive distillation system. **Engineering Optimization**, v. 37, n. 7, p. 733–753, 2005.

PANNOCCHIA, G.; RAWLINGS, J. B. Disturbance models for offset-free model-predictive control. **AIChE Journal**, v. 49, n. 2, p. 426–437, 2003.

PATEL, J.; UYGUN, K.; HUANG, Y. A path constrained method for integration of process design and control. **Computers and Chemical Engineering**, v. 32, n. 7, p. 1373–1384, 2008.

PINTARIČ, Z. N.; KRAVANJA, Z. A strategy for MINLP synthesis of flexible and operable processes. **Computers and Chemical Engineering**, v. 28, n. 6–7, p. 1105–1119, 2004.

QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control Engineering Practice**, v. 11, p. 733–764, 2003.

RAFIEI-SHISHAVAN, M.; MEHTA, S.; RICARDEZ-SANDOVAL, L. A. Simultaneous design and control under uncertainty : A back-off approach using power series expansions. **Computers and Chemical Engineering**, v. 99, p. 66–81, 2017.

RAFIEI, M.; RICARDEZ-SANDOVAL, L. A. New frontiers, challenges, and opportunities in integration of design and control for enterprise-wide sustainability. **Computers and Chemical Engineering**, v. 132, 2020.

RAWLINGS, J. B.; STEWART, B. T. Coordinating multiple optimization-based

controllers: New opportunities and challenges. **Journal of Process Control**, v. 18, n. 9, p. 839–845, 2008.

REVOLLAR, SILVANA; HERNÁN, ALVAREZ; LAMANNA, ROSALBA; VEGA, PASTORA; FRANCISCO, M. Multi-objective Genetic Algorithms for the Integrated Design of Chemical Processes Using Advanced Control Techniques. **In 20<sup>th</sup> European Symposium on Computer Aided Process Engineering**, 2010.

RICARDEZ-SANDOVAL, L. A. Optimal design and control of dynamic systems under uncertainty: A probabilistic approach. **Computers and Chemical Engineering**, v. 43, p. 91–107, 2012.

RICARDEZ-SANDOVAL, L. A.; BUDMAN, H. M.; DOUGLAS, P. L. Integration of design and control for chemical processes: A review of the literature and some recent results. **Annual Reviews in Control**, v. 33, n. 2, p. 158–171, 2009.

SAKIZLIS, V.; PERKINS, J. D.; PISTIKOPOULOS, E. N. Parametric Controllers in Simultaneous Process and Control Design Optimization. **Industrial & Engineering Chemical Research**, v. 42, n. 20, p. 4545–4563, 2003a.

SAKIZLIS, V.; PERKINS, J. D.; PISTIKOPOULOS, E. N. Parametric controllers in simultaneous process and control design. **Computer Aided Chemical Engineering**, v. 15, p. 1020–1025, 2003b.

SANCHEZ-SANCHEZ, K. B.; RICARDEZ-SANDOVAL, L. A. Simultaneous Process Synthesis and Control Design under Uncertainty: A Worst-Case Performance Approach. **AIChE Journal**, v. 59, p. 2497–2514, 2013a.

SANCHEZ-SANCHEZ, K. B.; RICARDEZ-SANDOVAL, L. A. Simultaneous design and control under uncertainty using model predictive control. **Industrial and Engineering Chemistry Research**, v. 52, n. 13, p. 4815–4833, 2013b.

SANTANDER, O. **Economic model predictive control of chemical processes**. Waterloo: University of Waterloo, 2015. 122 p. Dissertação (Mestrado).

SANTANDER, O.; ELKAMEL, A.; BUDMAN, H. Economic model predictive control of chemical processes with parameter uncertainty. **Computers and Chemical Engineering**, v. 95, p. 10–20, 2016.

SCHWEIGER, C. A.; FLOUDAS, C. A. Interaction of Design and Control: Optimization with Dynamic Models. In **Optimal Control: Theory, Algorithms, and Applications**. Boston, MA: Springer US, 1998. p. 388–435.

SEBORG, D. E.; THOMAS F. EDGAR. **Process Dynamics and Control**. John Wiley & Sons, 2012, 596 p.

SHARIFZADEH, M. Integration of process design and control: A review. **Chemical Engineering Research and Design**, v. 91, n. 12, p. 2515-2549, 2013.

SHI, K.; YUAN, X.; LIU, L. Model predictive controller-based multi-model control system for longitudinal stability of distributed drive electric vehicle. **ISA Transactions**, v. 72, p. 44–55, 2018.

SILVA-BEARD, A.; FLORES-TLACUAHUAC, A. Effect of process design/operation on the steady-state operability of a methyl methacrylate polymerization reactor. **Industrial and Engineering Chemistry Research**, v. 38, n. 12, p. 4790–4804, 1999.

SKOGESTAD, S. Plantwide control: the search for the self-optimizing control structure. **Journal of Process Control**, v. 10, n. 5, p. 487-504, 2000.

SKOGESTAD, S. Feedback: Still the simplest and best solution. **Modeling, Identification and Control**, v. 30, n. 3, p. 149–155, 2009.

STEPHANOPOULOS, G.; NG, C. Perspectives on the synthesis of plant-wide control structures. **Journal of Process Control**, v. 10, n. 2, p. 97–111, 2000.

STRUTZEL, F. A. M. **Controle IHMPC de um processo industrial de hidrotreatamento de diesel**. São Paulo: Escola Politécnica, Universidade de São Paulo, 2014, 106 p. Dissertação (Mestrado).

STRUTZEL, F. A. M.; BOGLE, I. D. L. Assessing plant design with regard to MPC performance. **Computers and Chemical Engineering**, v. 94, p. 180–211, 2016.

TRAINOR, M.; GIANNAKEAS, V.; KISS, C.; RICARDEZ-SANDOVAL, L. A. Optimal process and control design under uncertainty: A methodology with robust feasibility and stability analyses. **Chemical Engineering Science**, v. 104, p. 1065–1080, 2013.

VAN DE WAL, M.; DE JAGER, B. Review of methods for input/output selection. **Automatica**, v. 37, n. 4, p. 487–510, 2001.

VEGA, P.; LAMANNA, R.; REVOLLAR, S.; FRANCISCO, M. Integrated design and control of chemical processes - Part II: An illustrative example. **Computers and Chemical Engineering**, v. 71, p. 618–635, 2014a.

VEGA, P.; LAMANNA, R.; REVOLLAR, S.; FRANCISCO, M. Integrated design and control of chemical processes – Part I: Revision and classification. **Computers and Chemical Engineering**, v. 71, p. 602–617, set. 2014b.

WANG, L. **Model Predictive Control System Design and Implementation Using MATLAB**. Springer, ed. London: Springer, London, 2009, 403 p.

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

XAVIER, J. E. S. C. **Aplicação do Filtro de Kalman na correcção de dados provenientes de um sistema de Localização baseado em RFID**. Porto: Faculdade de Engenharia da Universidade do Porto, 2011, 76 p. Dissertação (Mestrado).

YUAN, Z.; CHEN, B.; SIN, G.; GANI, R. State-of-the-art and progress in the optimization-based simultaneous design and control for chemical processes. **AIChE Journal**, v. 58, n. 6, p. 1640–1659, jun. 2012.

ZHOU, M.; LI, L.; XIE, L.; CAI, Y.; PAN, H. Preparation of Papers for IFAC

Conferences & Symposia: Integration of process design and control using hierarchical control structure. **IFAC-PapersOnLine**, v. 28, n. 8, p. 188–192, 2015.