



UMA NOVA METODOLOGIA NMPC INTEGRADA COM UMA CAMADA DE
OTIMIZAÇÃO PARA MAXIMIZAR A PRODUÇÃO DE ÓLEO OFFSHORE
COM ESPECIFICAÇÕES DE QUALIDADE

Leonardo Dorigo Ribeiro

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Química, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Química.

Orientador: Argimiro Resende Secchi

Rio de Janeiro
Junho de 2019

UMA NOVA METODOLOGIA NMPC INTEGRADA COM UMA CAMADA DE
OTIMIZAÇÃO PARA MAXIMIZAR A PRODUÇÃO DE ÓLEO OFFSHORE
COM ESPECIFICAÇÕES DE QUALIDADE

Leonardo Dorigo Ribeiro

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA QUÍMICA.

Examinada por:

Prof. Argimiro Resende Secchi, D.Sc.

Prof. Maurício Bezerra de Souza Jr, D.Sc.

Prof. Márcia Peixoto Vega Domiciano, D.Sc.

Dr. Mário César Mello Massa de Campos, D.Sc.

Prof. Bruno Didier Olivier Capron, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2019

Ribeiro, Leonardo Dorigo

Uma nova metodologia NMPC integrada com uma camada de otimização para maximizar a produção de óleo offshore com especificações de qualidade/Leonardo Dorigo Ribeiro. – Rio de Janeiro: UFRJ/COPPE, 2019.

XX, 149 p.: il.; 29,7cm.

Orientador: Argimiro Resende Secchi

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Química, 2019.

Referências Bibliográficas: p. 131 – 142.

1. Controle Preditivo Não Linear. 2. Otimização. 3. Processo de produção de óleo e gás offshore. I. Secchi, Argimiro Resende. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Química. III. Título.

*A alguém cujo valor é digno
desta dedicatória.*

Agradecimentos

A Deus, pois sem ele nada seria possível.

Aos meus pais, que com amor e dedicação propiciaram todo o alicerce para que eu pudesse chegar até aqui.

À minha querida esposa, Marcelle, pelo companherismo, compreendendo aos momentos de ausência durante toda a realização do trabalho e ao meu filho Gabriel, amor infinito, que mudou a minha forma de enxergar o mundo.

Aos grandes mestres Evaristo e Enrique Lima, peças fundamentais na minha formação acadêmica.

Ao meu orientador, Argimiro, por todo conhecimento transmitido durante essa longa jornada, paciência e confiança, com que sempre pude contar nos momentos difíceis.

Aos meus amigos de LADES, Evandro, Franklin, Cido, Pedro, Bendia, Diego Prata, Almeida, Silvio pelo convívio ao longo desses anos. Em especial, aos amigos Lizandro e Thiago, companheiros de longas conversas aprazíveis.

Ao mestre Paiva por todo ensinamento passado, sempre com paciência e didática.

Aos amigos da Petrobras, Gregório, Jacques, Natã, Luiz Paulo, Mário Campos, Marcos, Denise, Fábio, Lívia, Bruna, Mário Gomes, Marcelo, Patrícia, Lilian pelo conhecimento compartilhado e amizade, mostrando que é possível conviver em um ambiente de trabalho prazeroso.

Aos funcionários, em especial a Vera por sempre demonstrar solicitude na solução dos problemas, e aos professores do Programa de Engenharia Química da COPPE.

À Petrobras, pelo suporte para a realização do trabalho.

A todos que passaram em minha vida, contribuindo de forma direta ou indireta nesta jornada.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

UMA NOVA METODOLOGIA NMPC INTEGRADA COM UMA CAMADA DE OTIMIZAÇÃO PARA MAXIMIZAR A PRODUÇÃO DE ÓLEO OFFSHORE COM ESPECIFICAÇÕES DE QUALIDADE

Leonardo Dorigo Ribeiro

Junho/2019

Orientador: Argimiro Resende Secchi

Programa: Engenharia Química

A indústria de óleo e gás é impactada por ciclos de baixo crescimento econômico. Nesse contexto, técnicas de NMPC e de otimização que auxiliam a operabilidade da planta são de fundamental importância para o negócio. Contudo, o uso em escala industrial requer a superação de desafios, como por exemplo: determinação dos modelos de processo, tempo computacional adequado para obtenção da solução e integração entre as camadas de controle e otimização. Nesse trabalho é proposta uma metodologia para obter modelos analíticos de predição baseado na estrutura de Hammerstein, reduzindo o esforço computacional. As abordagens tradicionais transformam o modelo do NMPC, descrito por equações algébrico-diferenciais (DAE), em uma aproximação numérica baseada em equações algébricas não lineares (NLA), como por exemplo, colocação ortogonal. Na abordagem proposta, o NLA obtido é uma descrição eficaz do sistema original de DAE's, sendo independente de aproximações numéricas. O algoritmo proposto foi aplicado em um CSTR não-isotérmico integrado com camada de otimização. Os resultados mostram que a proposta apresenta redução no tempo computacional sem perda de desempenho, quando comparado com o NMPC usando modelo rigoroso. Além disso, o NMPC proposto conduziu a planta ao ponto ótimo vindo da otimização, sem apresentar problemas devido à diferença de modelos entre as camadas. Uma importante contribuição do trabalho é a aplicação do NMPC proposto integrado com camada de otimização em um processo de produção de óleo e gás. Os resultados também mostram bom desempenho do NMPC proposto em estabilizar o processo durante regimes de fluxo golfante, mantendo os requisitos de qualidade dentro das restrições e conduzindo o processo até o ponto ótimo obtido na otimização.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

A NEW METHODOLOGY OF NMPC INTEGRATED WITH AN
OPTIMIZATION LAYER TO INCREASE THE PRODUCTION OF OFFSHORE
OIL WITH QUALITY REQUIREMENTS

Leonardo Dorigo Ribeiro

June/2019

Advisor: Argimiro Resende Secchi

Department: Chemical Engineering

The oil and gas industry is impacted by low growth economic cycles. For this reason, techniques of NMPC and optimization that help the operability of the plant are very important for the business. However, the use of these tools in industry requires overcoming some challenges, for instance: find accurate models of the process, computational time suitable for obtaining the solution and integrate the layers of control and optimization. In this work a methodology is proposed to obtain analytical models based on hammerstein structure, reducing the computational time. Unlike most common approaches that transform NMPC internal model, described by differential-algebraic equations (DAE), into an approximate system of nonlinear algebraic equations (NLA) using, for instance, orthogonal collocation. In the proposed approach, the obtained NLA is an exact description of the original DAEs system. The proposed algorithm was applied to a non-isothermal CSTR integrated with an optimization layer. The results show that the proposed structure presents significant reduction in computational time without performance loss, when compared with the NMPC using rigorous model. Moreover, the proposed strategy demonstrated good performance in tracking the targets sent by the optimization layer, without model mismatches between layers. An important contribution of the work is the application of the proposed NMPC integrated with an optimization layer in an oil and gas production process. The results show good performance of the proposed algorithm to stabilize the process during slug flow conditions, keeping the quality requirement inside the constraints and driving the process to the optimal point obtained in the optimization layer.

Sumário

Lista de Figuras	xi
Lista de Tabelas	xvi
Lista de Símbolos	xvii
Lista de Abreviaturas	xx
1 Introdução	1
1.1 Objetivo	3
1.2 Contribuições do trabalho	3
2 Revisão Bibliográfica	9
2.1 Fundamentos das técnicas de Controle Preditivo Multivariável	9
2.1.1 Algoritmo de controle preditivo multivariável utilizando modelos lineares (MPC)	10
2.1.2 Algoritmo de controle preditivo multivariável utilizando modelos não lineares (NMPC)	17
2.1.3 Modelagem do processo controlado	19
2.1.4 Metodologia de identificação de processo para obtenção dos modelos utilizados pelo NMPC	24
2.1.5 Estratégias de solução do problema de controle preditivo não-linear - NMPC	26
2.2 Fundamentos da Otimização de processo	33
2.2.1 Estratégia de Otimização Estacionária (RTO)	34
2.2.2 Integração das camadas de otimização e de controle preditivo multivariável	36
2.2.3 Estratégia de Otimização Dinâmica (D-RTO)	41
2.3 Estado da arte de técnicas de controle e otimização aplicadas em processos industriais, com ênfase em produção de óleo <i>offshore</i>	46

3	Metodologia Proposta	52
3.1	Formulação do problema de controle	52
3.2	Determinação do modelo não linear	53
3.3	Integração do NMPC com a camada de otimização	57
4	Resultados e discussões	62
4.1	Caso 0 - Aplicação do NMPC proposto em um reator CSTR não-isotérmico	62
4.1.1	Identificação do Processo	65
4.1.2	Aplicação do NMPC proposto no estudo de caso do CSTR	70
4.1.3	Análise de sensibilidade aos erros de modelagem do modelo proposto para o NMPC	78
4.1.4	Comparação entre o controlador NMPC usando o modelo proposto e um algoritmo MPC adaptativo	83
4.1.5	Estudo de caso do desempenho do NMPC proposto na presença de perturbações não-medidas na vazão de fluido de resfriamento	85
4.1.6	Integração do NMPC proposto com uma camada de otimização	85
4.1.7	Considerações finais	90
4.2	Caso I - Aplicação do NMPC proposto em um processo de produção de óleo <i>offshore</i> modelado no EMSO	91
4.2.1	Desenvolvimento do modelo dinâmico	91
4.2.2	Descrição das unidades de processamento de óleo e de compressão de gás	92
4.2.3	Formulação do problema de controle	96
4.2.4	Determinação do modelo não linear	96
4.2.5	Resultados e discussões do caso I	101
4.2.6	Considerações finais do caso I	109
4.3	Caso II - Aplicação do NMPC proposto em um processo de produção de óleo offshore nos ambientes de simulação EMSO e OLGA	110
4.3.1	Breve descrição do processo de produção de óleo <i>offshore</i>	110
4.3.2	Resultados e discussões do caso II	111
4.4	Caso III - Aplicação do NMPC proposto integrado com uma camada de Otimização a processos de produção de óleo <i>offshore</i>	117
4.4.1	Formulação do problema de otimização	117
4.4.2	Resultados e discussões do caso III	118
4.4.3	Considerações finais do caso III	125
5	Conclusões	126

Referências Bibliográficas	131
A Desenvolvimento do modelo em estado-estacionário	143
B Desenvolvimento do modelo dinâmico	145
C Definição do produto de Hadamard HORN (1994)	149

Lista de Figuras

1.1	Fluxograma de Seleção da estrutura de Controle e Otimização.	4
2.1	Fluxograma da técnica de controle preditivo multivariável	10
2.2	Representação de blocos do modelo de Hammerstein (AGUIRRE, 2007).	22
2.3	Representação de blocos do modelo de Wiener AGUIRRE (2007).	23
2.4	Hierarquia de tomada de decisão (Pirâmide da automação) (ZANIN, 2001)	37
2.5	Otimização em duas camadas, ou seja, sem otimização na camada do controle preditivo multivariável (ZANIN, 2001).	40
2.6	Otimização em três camadas, clássica, com camada de otimização na camada de controle (ZANIN, 2001)	41
2.7	Árvore de seleção do método de solução de problemas de otimização dinâmica (DAOP) (ALMEIDA e SECCHI, 2012)	42
2.8	Método direto utilizando abordagem single-shooting (ALMEIDA e SECCHI, 2012).	43
2.9	Estratégia de controle antigolfada	47
2.10	Fluxograma de exploração de óleo e gás via injeção de <i>gas-lift</i>	49
3.1	Metodologia de identificação não-linear proposta.	56
4.1	Esquema do reator de Van De Vusse.	62
4.2	Composição do estado estacionário de C_b	64
4.3	identificação do modelo dinâmico da concentração do componente B, C_b	67
4.4	Identificação do modelo dinâmico da Temperatura de reação	68
4.5	Identificação do modelo de estado-estacionário da concentração do componente B, C_b	69
4.6	Identificação do modelo de estado-estacionário para a Temperatura.	69
4.7	Resultado do NMPC proposto para conduzir a planta até os alvos sugeridos para as variáveis controladas C_b e T , sendo a malha de controle fechada no instante de tempo 15 min e a alteração no alvo de C_b realizada no instante de tempo 150 min	71

4.8	Resultado do NMPC proposto para conduzir a planta até os alvos sugeridos para as variáveis controladas C_b e T , sendo a malha de controle fechada no instante de tempo 15 min e a alteração no alvo de T realizada no instante de tempo 150 min	72
4.9	Resultado do NMPC proposto para rejeitar perturbações na composição da vazão de alimentação, sendo a malha fechada no instante de tempo 15 min e com a perturbação aplicada no instante de tempo 150 min	73
4.10	Resultado do NMPC proposto para rejeitar perturbações na temperatura da vazão de alimentação, sendo a malha fechada no instante de tempo 15 min e com a perturbação aplicada no instante de tempo 150 min	74
4.11	Comparação entre as variáveis controladas obtidas com o NMPC proposto e uma estratégia QDMC tradicional.	76
4.12	Comparação entre as variáveis manipuladas obtidas como solução do problema de controle do NMPC proposto com uma estratégia tradicional QDMC.	76
4.13	Comparação entre as variáveis controladas obtidas com o algoritmo NMPC usando o modelo proposto e com o algoritmo usando o modelo rigoroso.	77
4.14	Comparação entre as variáveis manipuladas obtidas com o algoritmo NMPC usando o modelo proposto e com o algoritmo usando o modelo rigoroso.	77
4.15	Resultado do NMPC proposto com erro de modelagem de estado estacionário, cujo objetivo é manter C_b e a temperatura no setpoint. O controlador entra em operação no instante $t=15\text{min}$ e uma perturbação é adicionada ao sistema em $t=150\text{min}$	79
4.16	NMPC proposto com erros no modelo estático para o problema servo. A malha de controle é fechada em $t=15\text{ min}$ e o setpoint muda em $t=150\text{ min}$	80
4.17	NMPC proposto com erros no modelo dinâmico em τ_p para o problema servo. A malha de controle é fechada em $t=15\text{ min}$ e o setpoint muda em $t=150\text{ min}$	80
4.18	NMPC proposto com erros no modelo dinâmico em ϵ para o problema servo. A malha de controle é fechada em $t=15\text{ min}$ e o setpoint muda em $t=150\text{ min}$	81
4.19	NMPC proposto com erros no modelo estático para o problema regulatório. A malha de controle é fechada em $t=15\text{ min}$ e a perturbação ocorre em $t=150\text{ min}$	82

4.20	NMPC proposto com erros no modelo dinâmico em τ_p para o problema regulatório. A malha de controle é fechada em $t=15$ min e a perturbação ocorre em $t=150$ min.	82
4.21	NMPC proposto com erros no modelo dinâmico em ϵ para o problema regulatório. A malha de controle é fechada em $t=15$ min e a perturbação ocorre em $t=150$ min.	83
4.22	Comparação entre o NMPC com o modelo proposto e o MPC adaptativo.	84
4.23	Resultados do NMPC proposto para rejeitar perturbações não medidas na temperatura do fluido de refrigeração no instante $t = 200$ min.	85
4.24	Resultado do NMPC proposto com a camada de otimização	87
4.25	Comparação entre a otimização usando modelo estáticos com o modelo multi-paramétrico proposto e o modelo rigoroso	87
4.26	Comparação entre os alvos da otimização usando modelo estáticos com o modelo multi-paramétrico proposto e o modelo rigoroso	88
4.27	Comparação entre os resultados obtidos através de otimização dinâmica e os obtidos com otimização utilizando modelos estáticos.	89
4.28	Fluxograma de processo da unidade de processamento de óleo <i>offshore</i> modelado no simulador EMSO (SOARES e SECCHI, 2003).	94
4.29	Fluxograma da unidade de compressão de gás <i>offshore</i> modelado no simulador EMSO (SOARES e SECCHI, 2003).	95
4.30	Esquema do balanço de massa do poço.	98
4.31	Representação do modelo proposto usando a estrutura de Hammerstein.	98
4.32	Trajetória de predição calculada pelo modelo proposto para cada degrau nas variáveis de entrada.	100
4.33	Comparação entre o estado-estacionário descrito pelo modelo e o descrito pela planta para a produção de óleo.	103
4.34	Comparação entre os pontos de estado-estacionário obtidos pelo modelo proposto e pela planta para o TOG na vazão de água descartada.	104
4.35	Comparação entre os pontos de estado-estacionário obtidos pelo modelo proposto e pela planta para o BSW na vazão de produção de óleo.	104
4.36	Comparação entre as estratégias MPC linear e NMPC com modelo proposto para conduzir a vazão de produção de óleo aos setpoints sugeridos.	106
4.37	Comparação entre as estratégias de MPC com modelo linear e do NMPC proposto para mitigar golfadas.	106

4.38	Comparação entre as estratégias de MPC com modelo linear e do NMPC proposto para manter as especificações de <i>TOG</i> dentro dos limites.	107
4.39	Comparação entre as estratégias de MPC com modelo linear e do NMPC proposto para manter as especificações de <i>BSW</i> dentro dos limites.	107
4.40	Comparação das soluções do NMPC proposto e do QDMC para a vazão de injeção de gás-lift em cada poço.	108
4.41	Comparação das soluções do NMPC proposto e do QDMC para a abertura da válvula de choke de produção de cada poço.	108
4.42	Comparação das soluções do NMPC proposto e do QDMC para o nível de interface água-óleo do separador gravitacional.	109
4.43	Simulação do sistema subsea no simulador OLGA.	111
4.44	Relação entre as vazões de óleo, gás e água com a vazão de injeção de <i>gas-lift</i>	111
4.45	Resultados das variáveis controladas na aplicação da estratégia NMPC proposta em poços de produção de óleo <i>offshore</i>	112
4.46	Resultados das variáveis manipuladas da aplicação do NMPC proposto em processo de produção de óleo <i>offshore</i>	113
4.47	Comparação entre as estratégias de <i>Antislug</i> x PID-recursivo e o NMPC proposto.	115
4.48	Resultado da variável manipulada - Abertura da válvula de choke das estratégias de controle, NMPC, PID e <i>Antislug</i>	116
4.49	Resultado da variável manipulada - Vazão de injeção de <i>gas-lift</i> das estratégias de controle, NMPC, PID e <i>Antislug</i>	116
4.50	Relação entre as vazões de óleo, gás e água com a pressão no <i>topside</i>	118
4.51	Relação entre a pressão no <i>topside</i> com as variáveis de receita.	119
4.52	Relação entre a pressão no <i>topside</i> e as especificações de qualidade do processo.	119
4.53	Etapa de identificação para determinação dos modelos de estado-estacionário.	120
4.54	Comparação entre o modelo proposto e a planta.	121
4.55	Resultados do estado-estacionário para a produção de óleo.	122
4.56	Resultados do estado-estacionário para o consumo de energia.	122
4.57	Resultados do estado-estacionário para a produção de gás.	122
4.58	Comparação entre o modelo e a planta das principais variáveis que compõem o problema de otimização.	123
4.59	Resultados do NMPC integrado com a camada de otimização.	124

A.1	Representação do modelo multi-paramétrico para descrever as condições de estado-estacionário.	144
B.1	Modelo Hammerstein	145
B.2	Modelo proposto para descrever as dinâmicas do processo.	148

Lista de Tabelas

4.1	Parâmetros do estudo de caso do CSTR (DE VUSSE, 1964)	65
4.2	Parâmetros do modelo de estado-estacionário	65
4.3	Parâmetros do modelo dinâmico	66
4.4	Comparação entre as estruturas de otimização	88
4.5	Parâmetros do modelo estático da produção de óleo.	102
4.6	Parâmetros dos modelos estáticos de BSW_{SG}^{ss} e do TOG_{SG}^{ss}	102
4.7	Parâmetros dos modelos dinâmicos para a produção de óleo em cada poço.	103
4.8	Parâmetros dos modelos dinâmicos da produção de BSW e TOG. . .	103

Lista de Símbolos

H_λ	Gradiente de H em relação à $\lambda(t)$, p. 46
H_c	Horizonte de controle, p. 55
H_p	Horizonte de predição, p. 55
L_u	Peso das manipuladas na camada de otimização intermediária, p. 42
L_y	Peso das controladas na camada de otimização intermediária, p. 42
T	Frequência de atuação do controlador, p. 40
Δu	Ações de controle dentro do horizonte de controle nl , p. 40
\hat{y}^{ma}	Predição em malha aberta das variáveis controladas, p. 12
$\lambda(t)$	Multiplicadores de Lagrange, p. 46
R	Matriz de ponderação das ações de controle, p. 16
S	Matriz dinâmica, p. 13
W	Matriz de ponderação dos objetivos, p. 16
X	Matriz de estados do processo, p. 24
$\hat{\theta}$	Vetor de parâmetros do modelo estimado, p. 24
$\mathbf{d}(t_k)$	Vetor das perturbações no instante t_k , p. 55
$\mathbf{s}^u(t_k)$	Variáveis de folga de relaxação das restrições para as variáveis manipuladas, p. 63
$\mathbf{s}^x(t_k)$	Variáveis de folga de relaxação das restrições para as variáveis de estado, p. 63

$\mathbf{s}^y(t_k)$	Variáveis de folga de relaxação das restrições para as variáveis controladas, p. 63
$\mathbf{u}(t_k)$	Vetor das variáveis manipuladas no instante t_k , p. 55
\mathbf{u}^A	Valor ótimo de estado-estacionário para a variável manipulada obtida na otimização com o modelo proposto, p. 59
\mathbf{u}^I	Valor ótimo de estado-estacionário para a variável manipulada obtida na otimização intermediária, p. 60
\mathbf{u}^D	Valor ótimo para a variável manipulada obtida na otimização dinâmica, p. 62
\mathbf{u}^R	Valor ótimo de estado-estacionário para a variável manipulada obtida na otimização com o modelo rigoroso, p. 60
$\mathbf{y}(t_k)$	Vetor das variáveis controladas no instante t_k , p. 55
\mathbf{y}^A	Valor ótimo de estado-estacionário para a variável controlada obtida na otimização com o modelo proposto, p. 59
\mathbf{y}^{DR}	Valor ótimo para a variável controlada obtida na otimização dinâmica, p. 62
\mathbf{y}^I	Valor ótimo de estado-estacionário para a variável controlada obtida na otimização intermediária, p. 60
\mathbf{y}^R	Valor ótimo de estado-estacionário para a variável controlada obtida na otimização com o modelo rigoroso, p. 60
ν_1	Variável auxiliar que representa a vazão de água presente na fase oleosa , p. 102
ν_2	Variável auxiliar que representa a vazão de óleo presente na fase aquosa, p. 102
u^{*l}	Solução ótima das manipuladas da Otimização intermediária, p. 42
u^{*nl}	Solução ótima das manipuladas da Otimização não linear, p. 42
u_{at}	Variável manipuladas no instante atual, p. 40
y^{*l}	Solução ótima das controladas da Otimização intermediária, p. 42

y^{*nl}	Solução ótima das controladas da Otimização não linear, p. 42
y_P	Valores das predições para as variáveis controladas, p. 40

Lista de Abreviaturas

<i>BSW</i>	Basic Sediments water - Água e sedimentos presentes no óleo produzido, p. 1
<i>BSW_{SG}^{SS}</i>	Estado-estacionário da concentração de <i>BSW</i> na vazão de saída de óleo do separador gravitacional, p. 102
<i>DAEs</i>	Differential Algebraic Equations, p. 55
<i>DMC</i>	Dynamic Matrix Control, p. 10
<i>DRTO</i>	Dynamic Real Time Optimization, p. 1
<i>EMPC</i>	Economic Model Predictive Control, p. 32
<i>EMSO</i>	<i>Environment for Modeling, Simulation and Optimization</i> , p. 5
<i>LEMPC</i>	Lyapunov Economic Model Predictive Control - Garante os critérios de estabilidade de Lyapunov, p. 32
<i>LLT</i>	Linearização ao longo da Trajetória, p. 29
<i>MPC</i>	Model Predictive Control, p. 9
<i>NMPC</i>	Nonlinear Model Predictive Control, p. 1
<i>OCP</i>	Problema de Controle Ótimo, p. 30
<i>OLGA</i>	Simulador de escoamento multifásico de processos <i>offshore</i> , p. 5
<i>PNLSS</i>	Polinômio não-linear bem condicionado, p. 32
<i>QDMC</i>	Quadratic Dynamic Matrix Control, p. 17
<i>RTO</i>	Real Time Optimization, p. 1
<i>TOG</i>	Teor de óleos e graxas presentes na água produzida, p. 1
<i>TOG_{SG}^{SS}</i>	Estado-estacionário da concentração de <i>TOG</i> na vazão de saída de água do separador gravitacional, p. 102

Capítulo 1

Introdução

Unidades de produção de óleo *offshore* são marcadas por alta complexidade e por riscos ambientais. O fluido explotado é transportado desde os poços submarinos, *risers*, até a planta de processamento no *topside* da plataforma, sendo finalmente exportado através de oleodutos ou navios aliviadores. Algumas vezes, esse escoamento pode apresentar comportamento oscilatório, regimes golfantes, que podem ocasionar perdas de produção por paradas não programadas da planta, principalmente no sistema de compressão de gás da plataforma. Outro ponto importante, que merece ressalva, é a chegada de grande quantidade de líquido à plataforma, reduzindo o tempo de residência nos vasos de separação trifásico. Esse fato reduz a eficiência de separação, ocasionando a não especificação da quantidade de água e sedimentos no óleo exportado (BSW) e a quantidade de óleo na água descartada (TOG). A não especificação do BSW no óleo pode ocasionar problemas de corrosão nos oleodutos e equipamentos de processo *downstream*. Além disso, o não enquadramento da quantidade de óleo presente na água descartada pode gerar perdas financeiras devido ao pagamento de multas, além do próprio dano ao meio ambiente.

Nesse contexto, o uso de ferramentas de monitoração, controle preditivo, MPC e NMPC, e técnicas de otimização em tempo real, RTO e D-RTO, são conhecidas por ajudar na operabilidade de plantas industriais através da mitigação dos impactos de perturbações externas, estabilizando o processo, além de ajudar a manter as especificações de qualidade dentro dos limites, e, quando possível, conduzir a planta para um ponto ótimo operacional. Entretanto, o uso dessas ferramentas na indústria requer a superação de alguns desafios, os quais são:

- *Determinação de modelos eficazes em descrever o comportamento do processo; particularmente para relações não-lineares*
- *A solução do problema de controle deve ser obtida em tempo computacional adequado, para viabilizar a aplicação em tempo real;*

- A integração entre as camadas de controle e otimização deve garantir viabilidade, devido à diferença de modelagem entre as camadas de NMPC e de RTO ou D-RTO

Neste trabalho, é proposta uma metodologia para obter modelos analíticos para predição baseados na estrutura de Hammerstein para representar as não-linearidades do processo, reduzindo o esforço computacional em aplicações de tempo real. As abordagens tradicionais transformam o modelo interno do NMPC, descrito por um sistema de equações algébrico-diferenciais (DAE), em uma aproximação numérica baseada em um sistema de equações algébricas não lineares (NLA), como por exemplo, colocação ortogonal. Na abordagem proposta, o NLA obtido é uma descrição exata do sistema original de DAE's, melhorando o desempenho do controlador e reduzindo o custo computacional.

Um dos grandes desafios na aplicação de técnicas de controle preditivo em processos de produção *offshore* é a presença de não linearidades entre as principais variáveis operacionais da planta. O processo de produção de óleo *offshore* consiste em desde os poços *subsea*, *flowlines* e *risers*, até a planta de processamento no *topside*. A parte *subsea* consiste de poços, *flowline* e *riser*, modelados no ambiente de simulação OLGA e integrados com a planta de processamento do topside da plataforma, modelada no simulador EMSO. Sendo assim, é proposto um modelo não linear que representa adequadamente o sistema de produção *offshore* e viável em escala industrial para fins de controle e otimização. Fato relevante, pois um importante desafio para aplicações de algoritmos de controle preditivo não linear é a dificuldade em obter a solução do problema de controle em tempo computacional razoável, de forma que a solução obtida ainda seja válida para aplicação na planta.

Atualmente, a indústria de óleo e gás tem poços de produção *offshore* cada vez mais distantes da costa terrestre, ou seja, produzindo em águas profundas. Esses poços têm por característica grandes vazões de óleo e gás produzidas. Neste contexto, as plantas de processamento de óleo concebidas para produção *offshore* estão sendo construídas com flexibilidade operacional para destinação do gás produzido, podendo enviá-lo para exportação, *gas lift*, reinjeção no reservatório, ou no pior cenário queima no *flare*. Essa diversidade de modos de operação cria um campo fértil para formulação de um problema de otimização econômica, através dos seguintes caminhos : (1) *gas lift* - maximização de receita de óleo até um determinado ponto, porém há custos de compressão para fazê-lo e redução de receita com menor quantidade de gas exportado; (2) reinjeção no reservatório - custos de energia na compressão e redução de receitas com menor quantidade de gas exportado; (3) Exportação do gas - Gera receitas, porém tem que se respeitar a prioridade do *gas lift*, de forma a não faltar gás para realizar a operação que maximiza o óleo; e (4) Queima no *flare* - pior destino, pois há perdas de receita, pois o gas não está sendo

exportado, e aumento de custos, devido a multas da agência reguladora. Porém, é um destino viável, caso as outras opções já estejam nos seus limites e a produção de óleo ainda compense os custos.

Neste contexto, o NMPC proposto foi integrado com uma camada de otimização, cujo objetivo é maximizar a produção e minimizar o consumo de energia nos diversos modos de operação. Os graus de liberdade do problema de otimização são a pressão de *topside* da planta e as vazões de injeção de *gas-lift* em cada poço, enquanto as variáveis manipuladas do controlador são vazão de injeção de *gas-lift* e o choke por poço, além do nível de interface água-óleo do separador trifásico. As restrições presentes na formulação do problema de otimização são: as especificações de processo, BSW (Sedimentos e água no óleo) e TOG (Teor de óleos e graxas na água); a capacidade da unidade de compressão e os limites de pressão e vazão de injeção de *gas-lift*, em cada poço e total.

1.1 Objetivo

O objetivo é propor uma estrutura de controle preditivo não linear acoplada a técnicas de otimização com foco na redução do custo computacional, possibilitando sua aplicação em escala industrial. O trabalho é dividido em dois estudos de caso :

- Aplicação em um problema clássico da literatura - CSTR de Van De Vusse: (DE VUSSE, 1964)

A aplicação do NMPC proposto com camada de otimização neste estudo de caso tem o objetivo de avaliar o desempenho da estratégia desenvolvida em conduzir o processo para o ponto ótimo sugerido pela camada de otimização, utilizando como métrica o custo computacional para resolver o problema de controle e, com isso, avaliar seu potencial para problemas de maior dimensão.

- Aplicação em processo de produção de óleo e gás *offshore*:

Após validação da estratégia proposta em um estudo de caso benchmark da literatura, o NMPC com o modelo não linear proposto foi aplicado em uma planta industrial simulada de exploração de óleo e gás *offshore*, desde a seção *subsea* até a unidade de processamento no *topside* da plataforma.

1.2 Contribuições do trabalho

Nesta seção são apresentadas as contribuições técnico-científicas que o trabalho tem a oferecer. A Figura 1.1 ilustra as possíveis arquiteturas de controle e otimização propostas para aplicações em plantas industriais.

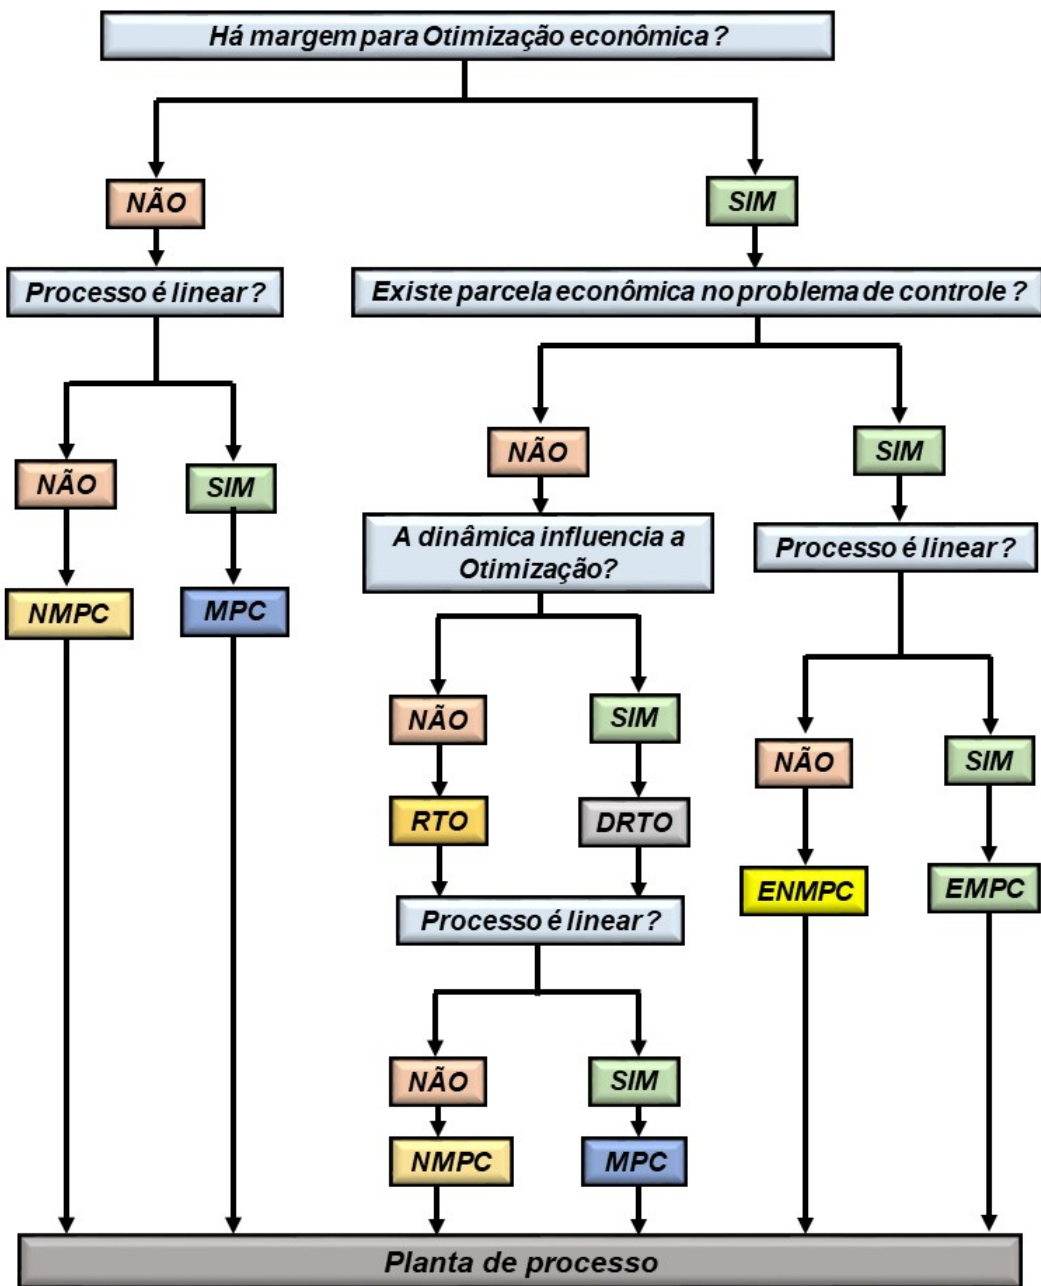


Figura 1.1: Fluxograma de Seleção da estrutura de Controle e Otimização.

Baseado no fluxograma apresentado na Figura 1.1, pode-se organizar a tese em quatro grandes áreas de estudo: modelagem do processo; identificação de processo; técnicas de controle preditivo não linear; e técnicas de otimização de processo. Dentro de cada uma dessas grandes áreas, são descritos os desafios e as contribuições esperadas.

- Etapa de modelagem dos estudos de caso

Nesta etapa foram selecionados o reator de Van de Vusse (DE VUSSE, 1964) como *benchmark* a ser utilizado para avaliar e validar os algoritmos de controle e otimização propostos e o processo de exploração de óleo e gás *offshore* como o caso industrial para aplicar as novas estratégias de controle e otimização.

- Desafios tecnológicos:

A modelagem do reator de Van de Vusse é um problema clássico da literatura que já foi amplamente estudado. Porém, dada a característica não linear do sistema, ainda há espaço para contribuições no que tange a estudos do comportamento do sistema em regimes permanente e dinâmico. Além da aplicação em um estudo de caso clássico da literatura, é visado estudar o desempenho das estratégias de controle e otimização propostas em aplicações industriais. Com esse foco, o processo de exploração de óleo e gás foi selecionado como caso de estudo. A modelagem do escoamento dos fluidos, desde o poço até a separação em óleo, gás e água, buscando estudos de dinâmica e de regime permanente é o desafio dessa etapa.

- Contribuições tecnológicas:

A principal contribuição desta etapa, consiste na integração entre o ambiente de simulação OLGA, onde foi modelado o escoamento de fluido, poços, *flowlines* e *risers*, com o simulador de processo EMSO (SOARES e SECCHI, 2003), em que foi simulado um caso real de uma planta de processamento *offshore*. A comunicação entre os ambientes foi através de protocolo OPC, propiciando condições para aplicar o NMPC proposto integrado com camada de otimização em um sistema simulado de produção *offshore*, englobando desde o poço *subsea* até a exportação dos fluidos produzidos.

- Etapa de Identificação de Processo.

Esta etapa do trabalho consiste em identificar modelos com características não lineares, que representem bem o comportamento do processo. Este ponto do trabalho é de suma importância, pois os modelos são o coração dos algoritmos de controle preditivo.

- Desafios tecnológicos:

O desafio neste momento está na proposição do modelo a ser utilizado e na estimação de seus parâmetros, de forma que seja possível representar adequadamente o comportamento do processo em estratégias de controle e otimização.

- Contribuições tecnológicas:

A obtenção dos parâmetros do modelo consiste em resolver um problema de otimização não linear, cujo objetivo é encontrar o conjunto de parâmetros que minimize o somatório ponderado do quadrado dos desvios, entre os valores observados e os valores estimados. A forma, possivelmente não convexa, da região de busca da solução não garante a determinação do ótimo global, fragilizando a solução obtida. Neste contexto, o trabalho apresenta uma metodologia de identificação de modelos não-lineares que contorna os obstáculos impostos pela não-convexidade da região de busca. Os resultados preliminares dessa abordagem são promissores e são discutidos mais a frente.

- Técnicas de Controle Preditivo Não Linear

Técnicas de controle preditivo não linear (NMPC) consistem em utilizar modelos representativos do processo, que consigam prever o comportamento da planta frente a perturbações e entradas definidas. Desta forma, o controlador atua na planta no sentido de conduzi-la a um objetivo específico. Esta estratégia de controle é repleta de desafios, no que diz respeito aos modelos utilizados pelo controlador, métodos de otimização não linear utilizados, abordagens para resolver o problema de controle e sintonias de controle. Esta etapa do trabalho foca na proposição do modelo e na abordagem para resolver o problema de controle.

- Desafios tecnológicos:

Os desafios das aplicações de técnicas NMPC são inúmeros, principalmente no que se refere a aplicações industriais. Existem duas técnicas de otimização usuais: simultânea e sequencial. Na abordagem simultânea, o problema de otimização é resolvido simultaneamente ao problema de

integração discretizado, este fato aumenta em muito o número de graus de liberdade do problema de otimização, o que inviabiliza a aplicação da técnica em problemas de larga escala, ou seja, é necessário o desenvolvimento de métodos de otimização mais eficazes para obtenção da solução do problema em tempo real. Na abordagem sequencial, o problema de otimização é resolvido em duas etapas, na primeira o otimizador define os valores dos graus de liberdade que serão utilizados na etapa de integração, após a integração do sistema, os valores da função objetivo e dos gradientes são retornados ao otimizador, e assim sucessivamente, até a obtenção da convergência. Este método necessita de alto esforço computacional, pois em todo passo do otimizador, o sistema é integrado novamente.

– Contribuições tecnológicas:

Nesse trabalho foi selecionada uma abordagem proposta direta, pois só existe o problema de otimização. A integração já foi feita previamente pela solução analítica. A grande contribuição desta etapa foi a proposição de um modelo analítico, ou seja, já integrado, a ser utilizado pelo otimizador. Desta forma, o NMPC tem uma significativa redução do esforço computacional, pois a etapa de integração foi suprimida pela existência dos modelos analíticos propostos. Assim sendo, é de extrema relevância a etapa de identificação para obtenção desses modelos.

● Técnicas de Otimização de Processo

As técnicas de otimização são cercadas por inúmeros desafios, principalmente quando aplicadas em tempo real. O fato dessa camada se utilizar de modelos rigorosos faz com que muitas informações da planta necessitem ser coletadas na etapa da modelagem, e nem sempre esses dados estão todos disponíveis. Além disso, a aplicação dessas técnicas em tempo real está cercada por etapas a priori que garantam a disponibilidade da planta para receber a solução proposta pelo RTO ou DRTO (MARLIN e FORBES, 1995).

Uma etapa relevante na aplicação das técnicas de otimização em plantas industriais é a de reconciliação de dados, realizada tanto no RTO quanto no DRTO. Essa etapa é fundamental, pois garante que os balanços de massa e energia da planta estão sendo reproduzidos pelo modelo. Além dessa etapa, para o RTO, há também a detecção do estado estacionário, que é de fundamental importância para o sucesso da otimização estática. O trabalho objetiva a proposição de uma estrutura de integração entre as camadas de RTO ou DRTO e a de NMPC.

– Desafios tecnológicos:

A aplicação de uma camada de otimização é complementar à camada de controle avançado, principalmente quando os modelos utilizados pelo controlador não contemplam toda a região de otimização da planta. Nesse contexto, é de fundamental importância o uso de técnicas de otimização com modelos fenomenológicos do processo e, portanto, mais representativos do comportamento da planta. Entretanto, o uso dessa formulação apresenta diversos desafios a serem explorados, principalmente no que se refere à otimização dinâmica e a aplicação em tempo real. Uma das maiores dificuldades está na modelagem fenomenológica do processo, de forma a representar bem os regimes dinâmico e estacionário da planta. Além disso, é fundamental o uso de métodos de otimização de busca global, que sejam robustos e eficazes o suficiente para concluírem suas buscas pelo ótimo, em frequências de atuação que os permitam ser aplicados em tempo real.

– Contribuições tecnológicas:

Esta parte do trabalho visa contribuir através de uma estrutura de controle e otimização aplicável a processos de exploração de óleo e gás *offshore*. Usualmente, as camadas de controle e de otimização apresentam modelos diferentes; a primeira é um modelo linear ou não linear, obtido através da identificação, o que torna o problema de controle mais simples de resolver, permitindo ao controlador atuar com uma frequência da ordem de segundos a minutos; enquanto que, a camada de otimização utiliza modelos rigorosos mais fidedignos a planta, porém mais complexos, o que dificulta a solução do problema, ocasionando uma frequência de atuação de horas para essa camada. A integração das camadas de controle e otimização é uma tarefa difícil e merece atenção, pois o controlador tem que levar a planta, de forma suave, ao ótimo sugerido pela camada de otimização acima e, muitas das vezes, essa tarefa torna-se inviável, dada a diferença entre os modelos das duas camadas e aos parâmetros de sintonia do controlador. Neste trabalho é proposta uma estratégia de integração entre a camada de otimização (RTO ou D-RTO) e o NMPC proposto, mitigando a diferença entre os modelos.

Capítulo 2

Revisão Bibliográfica

A revisão bibliográfica foi estruturada de acordo com a proposta de aplicar técnicas de otimização e de controle preditivo não linear em processos de produção de óleo *offshore*. Desta forma, o capítulo foi organizado nos seguintes tópicos:

- Fundamentos das técnicas de Controle Preditivo Multivariável;
- Fundamentos das técnicas de Otimização em tempo real;
- Estado da arte de técnicas de controle e otimização aplicadas em processos industriais, com ênfase em produção de óleo e gás *offshore*;

2.1 Fundamentos das técnicas de Controle Preditivo Multivariável

Estratégias de controle preditivo multivariável estão cada vez mais sendo aplicadas no ambiente industrial. Essa grande aceitabilidade deve-se ao fato das vantagens dessa abordagem frente às estruturas de controle clássico da literatura. Os trabalhos de GARCIA *et al.* (1989); RAWLINGS e MUSKE (1993); RICHALET *et al.* (1978) apresentam a superioridade do MPC frente aos controladores convencionais, em sistemas com presença de grandes tempos mortos ou sistemas de fase não mínima. O fato de o MPC utilizar modelos representativos do processo o possibilita tratar das interações entre as variáveis de entrada e saída, bem como as dinâmicas complexas que há entre elas. Além disso, essa técnica permite o acoplamento com técnicas de otimização da planta como um todo, bem como suas restrições operacionais. O trabalho de CAMACHO e BORDONS (1998) lista os motivos para o uso de técnicas MPC no meio industrial, como por exemplo: capacidade de operar com problemas multivariáveis, operação dentro dos limites de segurança e qualidade de produto, determinação da condição operacional ótima e predição da resposta do processo frente a perturbações.

A Figura 2.1 ilustra a atuação de um controlador MPC, cujo objetivo principal é encontrar a sequência de ações de controle que minimize o somatório dos erros quadráticos, obtidos pela diferença entre os setpoints das variáveis controladas e seus valores preditos, dentro de um horizonte de tempo.

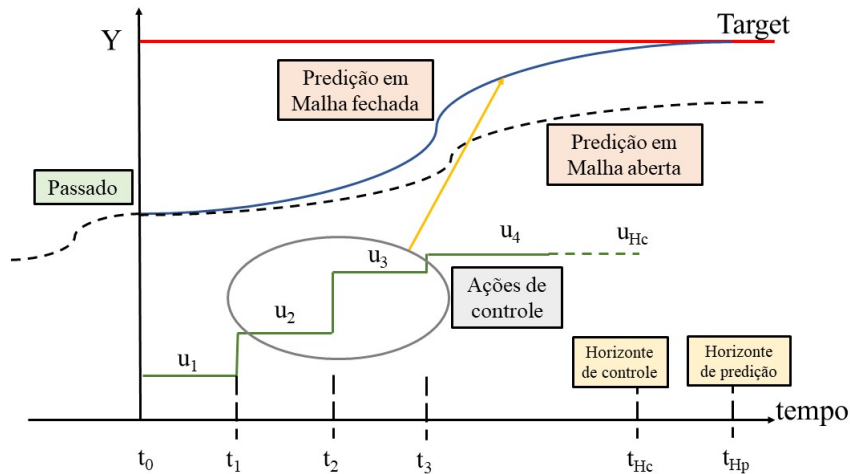


Figura 2.1: Fluxograma da técnica de controle preditivo multivariável

2.1.1 Algoritmo de controle preditivo multivariável utilizando modelos lineares (MPC)

Nesta seção é apresentado o algoritmo de controle preditivo multivariável, originário da teoria de controle ótimo, no qual as leis de controle são obtidas como solução de um problema dinâmico de otimização (KALMAN, 1960; PROPOI, 1963). Atualmente, existem vários algoritmos de controle preditivo, a maioria deles fundamentados no tipo de modelo representativo do processo. Como exemplo, podemos citar: GPC – *Generalized Predictive Control*, que utiliza modelos de função de transferência (CLARKE *et al.*, 1987); modelos baseados em representação espaço estado (PEREZ, 2006; RODRIGUES e ODLOAK, 2003), e o modelo apresentado por CUTLER e RAMAKER (1980) baseado em resposta ao impulso ou ao degrau (DMC). A seguir são apresentadas algumas dessas abordagens.

- Formulação SISO (*Single – Input / Single – Output*) do algoritmo DMC sem restrição;

A Equação 2.1 representa o valor da predição da variável controlada no instante de amostragem k em que h_j é o coeficiente de resposta ao impulso no instante

j , $u(k-j|j)$ é o histórico das ações de controle passadas e H_p é o período de estabilização da variável.

$$\hat{y}(k) = \sum_{j=1}^{H_p} h_j u(k-j) \quad (2.1)$$

Os coeficientes da resposta ao degrau são obtidos através do somatório dos coeficientes da resposta ao impulso.

$$S_j = \sum_{i=1}^j h_i \quad (2.2)$$

No instante k pode-se ler o valor da planta e calcular o erro de predição através de $y(k) - \hat{y}(k)$. Logo, corrigindo a predição, tem-se:

$$\hat{y}(k+1) = \sum_{j=1}^{H_p} h_j u(k+1-j) + (y(k) - \hat{y}(k)) \quad (2.3)$$

Substituindo a Equação 2.1 na Equação 2.3, chega-se a:

$$\hat{y}(k+1) = y(k) + \sum_{j=1}^{H_p} h_j \Delta u(k+1-j) \quad (2.4)$$

$$\hat{y}(k+1) = y(k) + h_1 \Delta u(k) + \sum_{j=2}^{H_p} h_j \Delta u(k+1-j) = y(k) + h_1 \Delta u(k) + P(1) \quad (2.5)$$

em que:

$$P(i) = \sum_{j=i+1}^{H_p} h_j \Delta u(k+i-j)$$

$$\hat{y}(k+2) = \hat{y}(k+1) + \sum_{j=1}^{H_p} h_j \Delta u(k+2-j) \quad (2.6)$$

Substituindo a Equação 2.5 na Equação 2.6 tem-se:

$$\hat{y}(k+2) = (h_1 + h_2)\Delta u(k) + h_1(k)\Delta u(k+1) + (y(k) + P(1) + P(2)) \quad (2.7)$$

Reescrevendo de forma genérica, chega-se a:

$$\begin{aligned} \hat{y}(k+j) = & (h_1 + h_2 + \dots + h_j)\Delta u(k) + (h_1 + h_2 + \dots + h_{j-1})\Delta u(k-1) + \\ & \dots + h_1(k)\Delta u(k+j-1) + (y(k) + P(1) + \dots + P(j)) \end{aligned} \quad (2.8)$$

Reescrevendo na forma matricial tem-se:

$$\begin{aligned} \begin{bmatrix} \hat{y}(k+1) \\ \hat{y}(k+2) \\ \vdots \\ \hat{y}(k+H_p) \end{bmatrix} = & \begin{bmatrix} h_1 & 0 & 0 & 0 \\ \sum_{i=1}^2 h_i & h_1 & 0 & 0 \\ \vdots & \vdots & \dots & \cdot \\ \sum_{i=1}^{H_p} h_i & \sum_{i=1}^{H_p-1} h_i & \dots & h_1 \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+H_p) \end{bmatrix} + \\ & \begin{bmatrix} y(k) + P(1) \\ y(k) + \sum_{i=1}^2 P(i) \\ \vdots \\ y(k) + \sum_{i=1}^{H_p} P(i) \end{bmatrix} \end{aligned} \quad (2.9)$$

Reescrevendo a Equação 2.9 pela resposta ao degrau, usando a 2.2:

$$\begin{aligned} \begin{bmatrix} \hat{y}(k+1) \\ \hat{y}(k+2) \\ \vdots \\ \hat{y}(k+H_p) \end{bmatrix} = & \begin{bmatrix} S_1 & 0 & 0 & 0 \\ S_2 & S_1 & 0 & 0 \\ \vdots & \cdot & \dots & \cdot \\ S_{H_p} & S_{H_p-1} & \dots & S_{H_p-H_c+1} \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+H_c-1) \end{bmatrix} + \\ & \begin{bmatrix} y(k) + P(1) \\ y(k) + \sum_{i=1}^2 P(i) \\ \vdots \\ y(k) + \sum_{i=1}^{H_p} P(i) \end{bmatrix} \end{aligned} \quad (2.10)$$

Considerando que \hat{y}^{ma} é o valor da predição em malha aberta, ou seja, considerando apenas as ações anteriores ao instante atual, tem-se:

$$\begin{bmatrix} \hat{y}^{ma}(k+1) \\ \hat{y}^{ma}(k+2) \\ \vdots \\ \hat{y}^{ma}(k+H_p) \end{bmatrix} = \begin{bmatrix} y(k) + P(1) \\ y(k) + \sum_{i=1}^2 P(i) \\ \vdots \\ y(k) + \sum_{i=1}^{H_p} P(i) \end{bmatrix} \quad (2.11)$$

Portanto, a Equação 2.12 representa a predição como função da matriz dinâmica \mathbf{S} e da predição em malha aberta $\hat{\mathbf{y}}^{ma} = \mathbf{y}^{atual} + \mathbf{P}$ (algoritmo DMC – Dynamic Matrix Control) (CAMPOS e PEREZ, 2013):

Em que :

$$\hat{\mathbf{y}}^{ma} = \begin{bmatrix} \hat{y}^{ma}(k+1) \\ \hat{y}^{ma}(k+2) \\ \vdots \\ \hat{y}^{ma}(k+H_p) \end{bmatrix}, \quad \mathbf{y}^{atual} = \begin{bmatrix} y(k) \\ y(k) \\ \vdots \\ y(k) \end{bmatrix} \quad \text{e} \quad \mathbf{P} = \begin{bmatrix} P(1) \\ \sum_{i=1}^2 P(i) \\ \vdots \\ \sum_{i=1}^{H_p} P(i) \end{bmatrix}$$

$$\hat{\mathbf{y}} = \mathbf{S} \Delta \mathbf{u} + \mathbf{y}^{atual} + \mathbf{P} \quad (2.12)$$

Em que :

$$\mathbf{S} = \begin{bmatrix} S_1 & 0 & 0 & 0 \\ S_2 & S_1 & 0 & 0 \\ \vdots & \cdot & \dots & \cdot \\ S_{H_p} & S_{H_p-1} & \dots & S_{H_p-H_c+1} \end{bmatrix} \quad \text{e} \quad \Delta \mathbf{u} = \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+H_c-1) \end{bmatrix}$$

Reescrevendo a equação 2.10 em termos do erro, diferença entre o vetor y_{SP} e o vetor de predição \hat{y} , temos :

$$\begin{bmatrix} y_{SP} - \hat{y}(k+1) \\ y_{SP} - \hat{y}(k+2) \\ \vdots \\ y_{SP} - \hat{y}(k+H_p) \end{bmatrix} = - \begin{bmatrix} S_1 & 0 & 0 & 0 \\ S_2 & S_1 & 0 & 0 \\ \vdots & \cdot & \dots & \cdot \\ S_{H_p} & S_{H_p-1} & \dots & S_{H_p-H_c+1} \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+H_c-1) \end{bmatrix} +$$

$$\begin{bmatrix} y_{SP} - y(k) - P(1) \\ y_{SP} - y(k) - \sum_{i=1}^2 P(i) \\ \vdots \\ y_{SP} - y(k) - \sum_{i=1}^{H_p} P(i) \end{bmatrix} \quad (2.13)$$

$$\begin{bmatrix} e(k+1) \\ e(k+2) \\ \vdots \\ e(k+H_p) \end{bmatrix} = - \begin{bmatrix} S_1 & 0 & 0 & 0 \\ S_2 & S_1 & 0 & 0 \\ \vdots & \cdot & \dots & \cdot \\ S_{H_p} & S_{H_p-1} & \dots & S_{H_p-H_c+1} \end{bmatrix} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+H_c-1) \end{bmatrix} +$$

$$\begin{bmatrix} e(k) - P(1) \\ e(k) - \sum_{i=1}^2 P(i) \\ \vdots \\ e(k) - \sum_{i=1}^{H_p} P(i) \end{bmatrix} \quad (2.14)$$

$$\mathbf{e} = -\mathbf{S} \Delta \mathbf{u} + \mathbf{e}(k) - \mathbf{P} \quad (2.15)$$

Definindo : $\mathbf{e}' = \mathbf{e}(k) - \mathbf{P}$

Com isso a Equação 2.12 é reescrita em termos do vetor de erros :

$$\mathbf{e} = -\mathbf{S} \Delta \mathbf{u} + \mathbf{e}' \quad (2.16)$$

Onde :

$\mathbf{e} = \mathbf{y}_{SP} - \hat{\mathbf{y}}$ - Vetor de erros entre os valores preditos e os desejados.

$\mathbf{e}' = \mathbf{e}(k) - \mathbf{P}$ - Vetor de erros sem ações de controle futuras.

Uma possível função objetivo para o controlador seria minimizar o erro entre uma trajetória de referência e os valores preditos ao longo do horizonte de tempo, Equação 2.17.

$$J = \mathbf{e}^T \mathbf{e} \quad (2.17)$$

O Controle preditivo tem por objetivo minimizar a função descrita pela Equação 2.17. Substituindo a Equação 2.16 na função objetivo.

$$J = (-\mathbf{S} \Delta \mathbf{u} + \mathbf{e}')^T (-\mathbf{S} \Delta \mathbf{u} + \mathbf{e}') \quad (2.18)$$

$$J = \Delta \mathbf{u}^T \mathbf{S}^T \mathbf{S} \Delta \mathbf{u} - \Delta \mathbf{u}^T \mathbf{S}^T \mathbf{e}' - \mathbf{e}'^T \mathbf{S} \Delta \mathbf{u} + \mathbf{e}'^T \mathbf{e}' \quad (2.19)$$

Considerando que não há restrições sobre as variáveis manipuladas e nem para as controladas, pode-se obter uma solução analítica para a Equação 2.19, através da Equação 2.20 abaixo.

$$\frac{\partial J}{\partial \Delta \mathbf{u}} = 2 \mathbf{S}^T \mathbf{S} \Delta \mathbf{u} - \mathbf{S}^T \mathbf{e}' - \mathbf{e}'^T \mathbf{S} = 0 \quad (2.20)$$

Substituindo o vetor de erros sem ações de controle futura, $\mathbf{e}' = \mathbf{e}(k) - \mathbf{P}$, na Equação 2.20, obtém-se a lei de controle para o problema sem restrição, Equação 2.21.

$$\Delta \mathbf{u} = (\mathbf{S}^T \mathbf{S}^T)^{-1} \mathbf{S}^T \mathbf{e}' = (\mathbf{S}^T \mathbf{S}^T)^{-1} \mathbf{S}^T (\mathbf{e}(k) - \mathbf{P}) \quad (2.21)$$

É importante lembrar que \mathbf{P} é a variação da variável controlada ocasionada pelas ações passadas ao instante atual, ou seja, em malha aberta e $e(k) = y_{SP} - y(k)$ é o erro do valor atual lido da planta, $y(k)$, em relação ao valor alvo y_{SP} .

- Formulação MIMO (*Multiple - Input / Multiple - Output*) do algoritmo DMC sem restrição;

Reformulando o problema para múltiplas entradas e múltiplas saídas.

$$\begin{aligned} \hat{y}_j(k) = & h_{j,1,1}(k)u_1(k-1) + h_{j,2,1}(k)u_2(k-1) + \dots + \\ & h_{j,nu,1}(k)u_{nu}(k-1) + h_{j,1,2}(k)u_1(k-2) + \dots + h_{ny,nu,H_p}(k)u_{nu}(k-H_p) \end{aligned} \quad (2.22)$$

Logo,

$$\begin{bmatrix} \hat{y}_1(k) \\ \vdots \\ \hat{y}_{ny}(k) \end{bmatrix} = \begin{bmatrix} h_{1,1,1} & h_{1,2,1} & \dots & h_{1,nu,1} \\ h_{2,1,1} & h_{2,2,1} & \dots & h_{2,nu,1} \\ \vdots & \vdots & \dots & \vdots \\ h_{ny,1,1} & h_{ny,2,1} & \dots & h_{ny,nu,1} \end{bmatrix} \begin{bmatrix} u_1(k-1) \\ u_2(k-1) \\ \vdots \\ u_{nu}(k-1) \end{bmatrix} + \dots$$

$$\begin{bmatrix} h_{1,1,H_p} & h_{1,2,H_p} & \dots & h_{1,nu,H_p} \\ h_{2,1,H_p} & h_{2,2,H_p} & \dots & h_{2,nu,H_p} \\ \vdots & \vdots & \dots & \vdots \\ h_{ny,1,H_p} & h_{ny,2,H_p} & \dots & h_{ny,nu,H_p} \end{bmatrix} \begin{bmatrix} u_1(k - H_p) \\ u_2(k - H_p) \\ \vdots \\ u_{nu}(k - H_p) \end{bmatrix} \quad (2.23)$$

Após algumas manipulações algébricas, obtém-se a expressão da predição para múltiplos canais, ou seja, uma representação da Equação 2.10 para o caso MIMO.

$$\begin{bmatrix} \hat{\mathbf{y}}_{k+1}^c \\ \hat{\mathbf{y}}_{k+2}^c \\ \vdots \\ \hat{\mathbf{y}}_{k+H_p}^c \end{bmatrix} = \begin{bmatrix} \mathbf{S}_1 & 0_{n_y n_u} & 0_{n_y n_u} & 0_{n_y n_u} \\ \mathbf{S}_2 & \mathbf{S}_1 & 0_{n_y n_u} & 0_{n_y n_u} \\ \vdots & \vdots & \ddots & \cdot \\ \mathbf{S}_{H_p} & \mathbf{S}_{H_p-1} & \dots & \mathbf{S}_{H_p-H_c+1} \end{bmatrix} \begin{bmatrix} \Delta \mathbf{u}(k) \\ \Delta \mathbf{u}(k+1) \\ \vdots \\ \Delta \mathbf{u}(k+H_c-1) \end{bmatrix} + \begin{bmatrix} \mathbf{y}(k) \\ \mathbf{y}(k) \\ \vdots \\ \mathbf{y}(k) \end{bmatrix} + \begin{bmatrix} \mathbf{P}_1 \\ \mathbf{P}_2 \\ \vdots \\ \mathbf{P}_{H_p} \end{bmatrix} \quad (2.24)$$

- Modificação da função objetivo do algoritmo de controle preditivo multi-variável;

Nesta seção a função objetivo é reformulada, representada pela Equação 2.25, em que está presente um termo de supressão de movimento para as ações de controle e uma priorização de objetivos entre as variáveis controladas (CAMPOS e PEREZ, 2013).

$$J = \mathbf{e}^T \mathbf{W}^T \mathbf{W} \mathbf{e} + \Delta \mathbf{u}^T \mathbf{R} \Delta \mathbf{u} \quad (2.25)$$

Sendo:

$\Delta \mathbf{u}^T \mathbf{R} \Delta \mathbf{u}$ - O termo de supressão de movimento;

\mathbf{W} - Matriz de ponderação dos objetivos.

\mathbf{R} - Matriz de ponderação das ações de controle.

A solução do problema para essa função objetivo, lembrando que se trata de um problema sem restrições é dada pela Equação 2.27.

$$\begin{aligned} \Delta \mathbf{u} &= (\mathbf{S}^T \mathbf{W}^T \mathbf{W} \mathbf{S} + \mathbf{R})^{-1} \mathbf{S}^T \mathbf{W}^T \mathbf{W} \mathbf{e}' = \\ &= (\mathbf{S}^T \mathbf{W}^T \mathbf{W} \mathbf{S} + \mathbf{R})^{-1} \mathbf{S}^T \mathbf{W}^T \mathbf{W} (\mathbf{e}(k) - \mathbf{P}) \end{aligned} \quad (2.26)$$

Lembrando que, $e(k) = y_{SP} - y(k)$ é o erro do valor atual lido da planta, $y(k)$, em relação ao valor alvo y_{SP} .

- Formulação do algoritmo de controle preditivo multivariável com restrições (QDMC);

O algoritmo QDMC utiliza as mesmas equações de predição das variáveis controladas e a mesma função objetivo, Equações 2.12 e 2.25.

Reescrevendo a Equação 2.25, tem-se:

$$J = \Delta \mathbf{u}^T \left(\underbrace{\mathbf{S}^T \mathbf{W}^T \mathbf{W} \mathbf{S} + \mathbf{R}}_{\mathbf{H}} \right) \Delta \mathbf{u} - 2 \underbrace{\mathbf{e}^T \mathbf{W}^T \mathbf{W} \mathbf{S}}_{\mathbf{C}_f^T} \Delta \mathbf{u} \quad (2.27)$$

Portanto, a formulação do problema quadrático (QDMC) é:

$$\min \{ J = \Delta \mathbf{u}^T \mathbf{H} \Delta \mathbf{u} - 2 \mathbf{C}_f^T \Delta \mathbf{u} \} \quad (2.28)$$

Sujeito às restrições:

$$\begin{aligned} \mathbf{u}_{min} &\leq \mathbf{u} \leq \mathbf{u}_{max} \\ \Delta \mathbf{u}_{min} &\leq \Delta \mathbf{u} \leq \Delta \mathbf{u}_{max} \\ \mathbf{y}_{min} &\leq \mathbf{S} \Delta \mathbf{u} + \mathbf{y}^{atual} + \mathbf{P} \leq \mathbf{y}_{max} \end{aligned}$$

2.1.2 Algoritmo de controle preditivo multivariável utilizando modelos não lineares (NMPC)

Nesta seção é apresentada a estrutura de um algoritmo NMPC. A formulação da função objetivo e das restrições do controlador é basicamente a mesma do controlador QDMC, diferindo apenas nos modelos utilizados, que no NMPC são não lineares enquanto que no QDMC são lineares. Contudo, o fato dos modelos utilizados serem não lineares acarreta uma mudança no problema de controle, que passa a ser um problema de programação não linear de solução mais complexa que o problema de programação quadrática do QDMC. Essa diferença dificulta a determinação da solução ótima do problema, bem como de determinar se o ótimo encontrado é global e não um mínimo local.

- Formulação do algoritmo NMPC no domínio discreto com modelos em representação em espaço-estado

As Equações 2.29 e 2.30 representam os modelos de espaço-estado, escritos no domínio discreto.

$$x(k+1) = F[x(k), u(k)] \quad (2.29)$$

$$y(k) = h[x(k)] \quad (2.30)$$

A formulação do problema de otimização do NMPC, de acordo com HENSON e SEBORG (1997), é dada por:

$$\min_{u(k|k), u(k+1|k), \dots, u(k+H_c-1|k)} = \phi[y(k+H_p|k)] + \sum_{j=0}^{H_p-1} L[y(k+j|k), u(k+j|k), \Delta u(k+j|k)] \quad (2.31)$$

A Equação 2.31 representa a formulação do problema de otimização, em que os $y(k+j)$ representam as predições das variáveis controladas, $u(k+j)$ são as variáveis manipuladas, ou seja, os graus de liberdade do problema de otimização, H_p o horizonte de predição, H_c o horizonte de controle e L e ϕ são as funções não lineares representadas pelas Equações 2.32 e 2.33, respectivamente.

$$L = [y(k+j|k) - y_s(k)]^T W [y(k+j|k) - y_s(k)] + [u(k+j|k) - u_s(k)]^T R [u(k+j|k) - u_s(k)] + [\Delta u(k+j|k)]^T S [\Delta u(k+j|k)] \quad (2.32)$$

em que W , R e S são matrizes de ponderação dos objetivos do controlador, sendo utilizadas como parâmetros de ajuste.

$$\phi = [y(k+H_p|k) - y_s(k)]^T W [y(k+H_p|k) - y_s(k)] \quad (2.33)$$

As restrições de desigualdade do problema de otimização são representadas pelas Equações 2.34 a 2.36 .

$$u_{min} \leq u(k+j|j) \leq u_{max}, \quad 0 \leq j \leq H_c - 1 \quad (2.34)$$

$$\Delta u_{min} \leq \Delta u(k+j|j) \leq \Delta u_{max}, \quad 0 \leq j \leq H_c - 1 \quad (2.35)$$

$$y_{min} \leq y(k+j|j) \leq y_{max}, \quad 0 \leq j \leq H_p \quad (2.36)$$

Enquanto que as restrições de igualdade são dadas por:

$$x(k+j|k) = F[x(k+j-1|k), u(k+j-1|k)], \quad 1 \leq j \leq H_p \quad (2.37)$$

$$y(k+j|k) = h[x(k+j|k)], \quad 1 \leq j \leq H_p \quad (2.38)$$

O problema de programação não linear (NLP) apresentado pelas equações acima é de difícil solução. Por exemplo, a técnica de programação quadrática sucessiva (SQP) não garante a determinação do mínimo global como solução do problema. Uma abordagem empregada é linearizar os modelos na condição de operação em cada instante de tempo, e obter a matriz jacobiana (BEQUETTE, 1991). Após isso, o problema é resolvido via algoritmo de programação quadrática (QP). A vantagem dessa abordagem é que o problema não linear (NMPC) se transforma em um LMPC (MPC com linearizações sucessivas) a cada instante de tempo.

2.1.3 Modelagem do processo controlado

A aplicação de técnicas NMPC para controlar e otimizar processos exige a formulação do problema de controle a ser resolvido, Equação 2.39.

$$\begin{aligned} \min_{u(k|k), u(k+1|k), \dots, u(k+H_c-1|k)} J = & \sum_{j=1}^{H_p} (y(k+j|k) - y^s(k+j|k))^T W_j (y(k+j|k) - y^s(k+j|k)) \\ & + \sum_{j=0}^{H_c-1} (u(k+j|k) - u^s(k+j|k))^T R_j (u(k+j|k) - u^s(k+j|k)) \\ & + \sum_{j=0}^{H_c-1} \Delta u^T(k+j|k) S_j \Delta u(k+j|k) + s^T T_j s \end{aligned} \quad (2.39)$$

$$\begin{aligned}
x(k+j|k) &= F[x(k+j-1|k), u(k+j-1|k)] & 1 \leq j \leq H_p \\
y(k+j|k) &= h[x(k+j|k)] & 1 \leq j \leq H_p \\
u_{min} &\leq u(k+j|k) \leq u_{max} & 0 \leq j \leq H_c - 1 \\
\Delta u_{min} &\leq \Delta u(k+j|k) \leq \Delta u_{max} & 0 \leq j \leq H_c - 1 \\
y_{min} - s_j &\leq y(k+j|k) \leq y_{max} + s_j & 1 \leq j \leq H_p \\
s_{min} &\leq s_j \leq s_{max} & 1 \leq j \leq H_p
\end{aligned}$$

Em que, s_j representa as variáveis de relaxamento das restrições flexíveis de máximo e mínimo para as variáveis controladas.

Durante a formulação do controlador algumas etapas devem ser cumpridas, são elas: modelagem do processo controlado, identificação dos parâmetros do modelo utilizado para descrever o processo e seleção da estratégia de solução do problema de controle preditivo não-linear.

Nesta seção são descritas estratégias de modelagem. Essa etapa é muito importante, pois o desempenho do controlador depende da acurácia do modelo em descrever o comportamento da planta. Existem na literatura científica diversas estruturas de modelos não lineares que podem ser usados em algoritmos de controle preditivo, como por exemplo, Nonlinear Auto Regressive external input (NARX)(SRINIWAS e ARKUN, 1997); modelos fuzzy (TATJEWSKI, 2007); modelos de Volterra (MANER *et al.*, 1997); modelos de Hammerstein e Wiener (WIENER, 1989). Esses modelos são estruturas não lineares fechadas chamadas de caixa-preta, pois não se conhece a interpretação física entre a natureza do processo e os parâmetros do modelo.

- Modelos NARMAX

São modelos discretos no tempo que explicam o valor da saída em função de valores prévios dos sinais de saída, de entrada e do ruído do modelo (AGUIRRE, 2007). A Equação 2.40 representa a forma de um modelo polinomial NARMAX sem atraso puro de tempo.

$$\begin{aligned}
y(k) &= F[y(k-1), y(k-2), \dots, y(k-p), u(k), u(k-1), \dots, u(k-p), & (2.40) \\
&e(k-1), e(k-2), \dots, e(k-r)] + e(k)
\end{aligned}$$

- Modelos de redes neuronais

Uma forma de representação de correlações não lineares entre variáveis é através

das redes neuronais. Este modelo é representado pelas equações abaixo (AGUIRRE, 2007):

Saída de um único neurônio com n entradas:

$$x = f\left(\sum_{j=1}^n w_j u_j(k) + b\right) \quad (2.41)$$

Existem várias funções de ativação, sendo que uma das mais comuns é a sigmoide.

$$f(z) = \frac{1}{1 + \exp^{-z}} \quad (2.42)$$

A saída de uma rede com um único nó na camada de saída e uma camada oculta é uma função não linear nos parâmetros do tipo:

$$y(k) = f_s \left\{ \sum_{i=1}^m w_i f_i \left(\sum_{j=1}^n w_{ij} u_j + b_i \right) + b_s \right\} \quad (2.43)$$

Sendo w_i os pesos da saída de cada neurônio da camada oculta e w_{ij} são os pesos da entrada j, vista pelo i-ésimo neurônio da camada oculta. A fim de estimar os parâmetros de uma rede neuronal multicamadas são utilizados algoritmos de estimação não linear, tais como o de retropropagação (HAYKIN, 1994) ou o operador de extensão (AGUIRRE, 2007; HAYKIN, 1996).

SU e MCAVOY (1997) utilizam técnicas de redes neuronais para representar um processo de copolimerização contínua. Esses modelos empíricos foram aplicados com estratégias NMPC, obtendo bons resultados.

- Modelos de Volterra

Uma forma de representar a saída $y(t)$ de um sistema não linear apenas com as entradas $u(t)$ é chamada de série de Volterra, definida no domínio contínuo pela Equação 2.44 (AGUIRRE, 2007).

$$y(t) = \int_{-\infty}^{\infty} \sum_{j=1}^{\infty} \int_{-\infty}^{\infty} h_j(\tau_1, \dots, \tau_j) \prod_{i=1}^j u(t - \tau_i) d\tau_i \quad (2.44)$$

Em que as funções h_j são chamadas de núcleos. Uma dificuldade prática da aplicação dessa série é o grande número de parâmetros que precisam ser estimados pela identificação. Uma das formas de reduzir o número de parâmetros a determinar

é utilizar funções ortonormais para representar esses parâmetros e, além disso, utilizar valores passados da saída como entrada para determinar $y(t)$, ou seja, utilizar auto-regressão da saída.

Seguindo essa linha, MANER *et al.* (1997) aplicaram a técnica de NMPC utilizando modelos de Volterra em um reator CSTR isotérmico, Equação 2.44. Essa abordagem obteve melhores resultados do que as técnicas de MPC, QDMC e LDMC, esse último apresenta problemas para grandes variações nas variáveis de entrada, pois prejudica a validade das linearizações realizadas em cada passo de predição. Este fato ocasiona problemas de desempenho do controlador. Outro trabalho interessante foi o proposto por MANER e DOYLE (1997), que se utilizou de modelos de segunda ordem de Volterra com termo linear autoregressivo para representar um processo de polimerização. Dessa forma a complexidade do problema não linear (NLP) independe do horizonte de predição escolhido.

SRINIWAS e ARKUN (1997) propuseram determinar o ótimo global do problema não linear através de mudanças de variáveis, de forma a transformar a função objetivo não linear e não convexa em uma função convexa com restrições convexas. Nesse trabalho, os autores utilizaram a estrutura de modelos ARX aplicadas ao MPC.

- Modelos de Hammerstein e Wiener

Esses modelos são obtidos via o acoplamento em cascata de um modelo linear $H(s)$ representativo da dinâmica do processo, que pode ser obtido por um modelo auto-regressivo (ARX), com um modelo não linear que descreve a parte estacionária do sistema, como por exemplo, funções splines (FRUZZETTI *et al.*, 1997), funções lineares e contínuas por parte (CERVANTES *et al.*, 2003a), wavelets (MIGLAN *et al.*, 2008), combinação de funções lineares (GOMES *et al.*, 2004) e redes neurais (LAWRYNCZUK, 2007).

A diferença entre o modelo de Hammerstein e Wiener está na sequência do acoplamento entre eles, ou seja, no Hammerstein o modelo não linear precede o linear, ordem oposta ao de Wiener, Figuras 2.2 e 2.3 (WIENER, 1989).

A Figura 2.2 é representada algebricamente pela Equação 2.45, modelo de Hammerstein.




Figura 2.2: Representação de blocos do modelo de Hammerstein (AGUIRRE, 2007).

$$\begin{aligned}
y(k) &= a_1 y(k-1) + \dots + a_{n_y} y(k-n_y) + b_1 \nu(k-1) + \dots + b_{n_u} \nu(k-n_u) \quad (2.45) \\
&= a_1 y(k-1) + \dots + a_{n_y} y(k-n_y) + b_1 f[u(k-1)] + \dots + b_{n_u} f[u(k-m)]
\end{aligned}$$

A Figura 2.3 é representada algebricamente pela Equação 2.46, modelo de Wiener.




Figura 2.3: Representação de blocos do modelo de Wiener AGUIRRE (2007).

$$\begin{aligned}
y(k) &= f[a_1 \nu(k-1) + \dots + a_{n_y} \nu(k-n_y) + b_0 u(k-\tau_d) + \dots + b_{n_u} u(k-n_u)] \quad (2.46) \\
&= f[a_1 f^{-1}(y(k-1)) + \dots + a_{n_y} f^{-1}(y(k-n_y)) + b_0 u(k-\tau_d) + \dots + b_{n_u} u(k-n_u)]
\end{aligned}$$

CHU e SEBORG (2003) utilizaram os modelos de Hammerstein em técnicas de NMPC e os resultados apresentados foram satisfatórios.

Um dos desafios na aplicação de técnicas NMPC é obter modelos que descrevam bem as características não lineares dos processos químicos. Seguindo essa linha, FRUZZETTI *et al.* (2010) utilizaram modelos de Hammerstein no sistema de controle para neutralização de pH e no sistema de controle para uma coluna de destilação binária. Os resultados demonstraram uma boa eficácia da modelagem em descrever os processos.

Essa busca por modelos que representem bem as não linearidades do processo e que sejam ao mesmo tempo robustos e de fácil implementação gerou uma quantidade significativa de trabalhos na literatura, dentre eles podemos citar o trabalho de CERVANTES *et al.* (2003a) que utilizaram os modelos de Wiener com linearizações da função não linear representativa do ganho estático, obtendo com isso uma função linear por partes. Esta abordagem possibilitou uma estrutura robusta para o controlador e foi aplicada em um reator CSTR e a um reator de polimerização, obtendo bons resultados para ambos os casos.

2.1.4 Metodologia de identificação de processo para obtenção dos modelos utilizados pelo NMPC

Nesta etapa são determinados os parâmetros dos modelos representativos do processo. Esses parâmetros são os graus de liberdade do problema de otimização, que consiste na minimização da função objetivo composta pelo somatório ponderado do quadrado dos desvios entre o valor observado e o valor estimado pelos modelos. O fato dos modelos serem não lineares dificulta a solução, pois torna o problema de otimização em um problema de programação não linear (NLP) cujo ótimo global é difícil de determinar.

Um dos grandes desafios do uso de técnicas NMPC em plantas industriais é a validade dos modelos identificados para condições de processo afastadas das condições operacionais as quais o modelo foi obtido. Nesse sentido, o modelo perde sua capacidade preditiva. Visando contornar esse problema, de forma a possibilitar o uso do controlador em largas faixas operacionais, MARINO e TOMEI (1993) apresentaram técnicas de estimação de parâmetro que atualizam em tempo real os parâmetros do modelo utilizado pelo controlador.

Outra dificuldade do uso de abordagens NMPC em problemas de larga escala está na etapa de excitação da planta que tem por objetivo levantar dados representativos das não linearidades do processo. Esses dados são utilizados a posteriori, na etapa de identificação não linear, de forma a se obter os modelos do processo. Seguindo essa linha, PEARSON e OGUNNAIKE (1997) discutem procedimento de excitação para plantas industriais para fins de construção de modelos empíricos com boa capacidade preditiva.

A seguir são descritas as estratégias de obtenção de parâmetros dos modelos empíricos utilizados em algoritmos de controle preditivo.

- Identificação Linear

Consiste na técnica de explicar o valor observado através de um vetor de regressores e dos parâmetros. O estimador linear de y é dado pela Equação 2.47 com ϵ representando o vetor de erros do estimador.

$$\mathbf{y} = \mathbf{X}\hat{\boldsymbol{\theta}} + \boldsymbol{\epsilon} \quad (2.47)$$

Em que $\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\theta}}$ é o vetor dos valores estimado de predição da controlada, $\mathbf{X} : R^N \times R^n$ é a matriz de estados da planta, $\hat{\boldsymbol{\theta}} \in \mathfrak{R}^n$ é o vetor de parâmetros do modelo estimado, $\mathbf{y} \in \mathfrak{R}^N$ é o vetor de valores medidos, $\boldsymbol{\epsilon} \in \mathfrak{R}^N$ é o vetor de desvios entre os valores medidos e estimados, sendo N o número de amostras, n o número de parâmetros do modelo estimado e $N \geq n$. Determina-se o conjunto de parâmetros que minimize o somatório do quadrado dos erros, Equação 2.48.

$$J_{MQ} = \sum_{i=1}^N \epsilon(i)^2 = \epsilon^T \epsilon = \|\epsilon\|^2 \quad (2.48)$$

Substituindo a Equação 2.47 na Equação 2.48 obtém-se:

$$J_{MQ} = \sum_{i=1}^N \epsilon(i)^2 = (\mathbf{y} - \mathbf{X}\hat{\theta})^T (\mathbf{y} - \mathbf{X}\hat{\theta}) = \mathbf{y}^T \mathbf{y} - \mathbf{y}^T \mathbf{X} \hat{\theta} - \hat{\theta}^T \mathbf{X}^T \mathbf{y} + \hat{\theta}^T \mathbf{X}^T \mathbf{X} \hat{\theta} \quad (2.49)$$

Visando minimizar a função custo J_{MQ} em relação $\hat{\theta}$, tem-se que resolver.

$$\frac{\partial J_{MQ}}{\partial \hat{\theta}} = \mathbf{0} \quad (2.50)$$

$$\frac{\partial J_{MQ}}{\partial \hat{\theta}} = -2 \mathbf{X}^T \mathbf{y} + 2 \mathbf{X}^T \mathbf{X} \hat{\theta} \quad (2.51)$$

Logo,

$$\hat{\theta} = [\mathbf{X}^T \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{y} \quad (2.52)$$

Como $\frac{\partial^2 J_{MQ}}{\partial \hat{\theta}^2} = 2 \mathbf{X}^T \mathbf{X} > \mathbf{0}$ é positiva definida, o valor $\hat{\theta}$ obtido pela Equação 2.52 minimiza o somatório do quadrado dos erros.

- Identificação Não Linear

Existem situações em que as variáveis possuem relações não lineares entre si, nesses casos o uso de estimadores lineares para representar o valor observado y através de regressores lineares não é eficiente. Portanto, o uso de estimadores não lineares para determinar o valor observado é o caminho mais viável, quando aplicações de mudanças de variáveis não são suficientes. Neste contexto, a função de minimização do somatório do quadrado dos erros é não linear, o que o torna em um problema de programação não linear (NLP), em que $f(\cdot)$ é a função não linear utilizada para representar o valor observado.

$$y = f(\mathbf{X}, \hat{\theta}) \quad (2.53)$$

$$\min_{\hat{\theta}} \left(J_{MQ} = \sum_{i=1}^N \epsilon(i)^2 = (\mathbf{y} - f(\mathbf{X}, \hat{\theta}))^T (\mathbf{y} - f(\mathbf{X}, \hat{\theta})) \right) \quad (2.54)$$

A minimização da função J_{MQ} necessita de um algoritmo de programação não linear, que nem sempre consegue garantir a determinação do ótimo global.

2.1.5 Estratégias de solução do problema de controle preditivo não-linear - NMPC

O algoritmo de NMPC consiste em resolver um problema de otimização não linear cujo foco é minimizar uma função objetivo sujeita a restrições, como o problema formulado na Equação 2.39. Visando resolver o problema de controle, são propostas algumas abordagens na literatura: transformação do problema não linear (NLP) em um problema linear (LP) através de técnicas de linearização; utilização de multimodelos lineares para representar as não linearidades; uso de modelos adaptativos, ou seja, com estimação dos parâmetros de acordo com o ponto de operação; métodos de seleção inteligente do algoritmo de controle e do método de integração mais adequados para o problema estudado. A seguir descrevem-se alguns trabalhos que se utilizam dessas abordagens.

Uma das barreiras ao uso de NMPC é a complexidade de resolver o problema de otimização, utilizando modelos não lineares na representação do comportamento do processo. Esse fato levou à proposição de técnicas de linearização local, com posterior solução do problema por técnicas de programação quadrática. Essa abordagem de linearizações sucessivas reduz um problema NMPC em um problema LMPC (Controle Preditivo Multivariável Linearizado). Porém, não é possível garantir que o comportamento não linear será completamente reproduzido. BEQUETTE (1991); BRENGEL e SEIDER (1989); LI e BIEGLER (1989) propuseram linearizações locais antes de cada etapa de execução do NMPC.

GATTU e ZAFIRIOU (1992); LEE e RICKER (1994) propuseram estimadores de estado para determinar o ponto local de linearização, na ausência de dados de planta suficientes para determiná-lo.

BEQUETTE *et al.* (1993) apresentaram um estudo comparativo de técnicas de otimização dinâmica, abordagem sequencial e abordagem simultânea, utilizadas em estratégias de controle preditivo não linear. O trabalho apresenta uma revisão do problema de controle preditivo não linear, Equação 2.55.

$$\min_{u(k)...u(k+H_c-1)} \Theta(u) = \int_{t_k}^{t_k+T_P} e^2 dt = \sum_{i=k+1}^{k+H_p} [y_{sp}(i) - y_{pred}(i)]^2 \quad (2.55)$$

Sujeito às restrições:

$$\dot{x} = f(x, u, p, t)$$

$$y_m = g(x)$$

$$u_{min} \leq u(i) \leq u_{max}$$

$$u(i-1) - \Delta u_{max} \leq u(i) \leq u(i-1) + \Delta u_{max}$$

$$u(i) = u(k + M - 1) \forall i > k + M - 1$$

$$x_{min} \leq x \leq x_{max}$$

$$x(t_k) = x_k$$

As técnicas de otimização dinâmica utilizadas para a solução do problema de controle preditivo não linear foram:

- Abordagem sequencial: o sistema de equações diferenciais ordinárias é resolvido em separado do problema de otimização, ou seja, em cada iteração do otimizador, o sistema de ODEs é integrado e tem os valores dos estados das variáveis determinados ao longo de todo o horizonte de predição, de forma a resolver as equações de sensibilidade para compor os gradientes da função objetivo (BEQUETTE *et al.*, 1993).
- Abordagem simultânea: Nesta abordagem o sistema de equações algébricas obtido via colocação ortogonal em elementos finitos é incorporado ao problema de otimização como restrições não lineares do problema. Essa metodologia resulta em um problema de otimização de dimensão elevada a ser resolvido, ocasionado pelo aumento do número de variáveis de decisão e do número de restrições não lineares, representados pelo acréscimo das variáveis de estado nos pontos de colocação em cada elemento finito (BEQUETTE *et al.*, 1993).

Essas abordagens foram testadas por BEQUETTE *et al.* (1993) em um reator CSTR exotérmico, demonstrando bons resultados para ambas. Porém, de acordo com os autores a abordagem simultânea demonstrou-se mais eficiente em relação ao custo computacional, porém mais complexa em termos de implementação, quando aplicadas ao exemplo em estudo. A necessidade do aprimoramento das técnicas de NMPC, de forma a torná-la mais robusta para aplicações em tempo real e em processos de larga escala, fez com que novas formulações do problema de controle surgissem. Nesta linha, pode-se citar o trabalho de LEE e RICKER (1994), em que os autores implantaram na planta de Tennessee Eastman (DOWNS e VOGEL, 1993) um NMPC com 26 variáveis de estado, 10 variáveis manipuladas e 23 variáveis controladas. Além disso, os autores utilizaram linearizações sucessivas e programação quadrática para determinação da predição e das ações de controle.

O uso de técnicas NMPC em problemas de grande dimensão exige um grande esforço computacional durante a etapa de resolução do problema de otimização. Para reduzir esse problema, ZHENG (1997) propôs uma formulação do algoritmo NMPC, de forma que apenas a primeira ação de controle é calculada utilizando modelo não linear e todas as outras ações são obtidas através do uso de modelos linearizados (LMPC).

Outro aspecto importante no uso de técnicas NMPC é a questão de garantia de estabilidade do controlador em malha fechada. CHEN e ALLGOWER (1997) propuseram uma matriz de penalização para a violação das restrições ao longo do horizonte de predição. Esta matriz é determinada *offline*, de forma a garantir a estabilidade do controlador quando atuando em malha fechada. Por outro lado, MAYNE (1997) propôs acrescentar o horizonte de predição como uma variável de decisão do controlador na busca pela estabilidade.

Alguns trabalhos da literatura apresentam bons resultados quanto à robustez de técnicas NMPC. Esses trabalhos utilizam critérios de estabilidade na formulação da função objetivo do controlador (BADGWELL, 1997; MAYNE e MICHALSKA, 1991c; NICOLAO *et al.*, 1996). HENSON e SEBORG (1997) utilizaram um controlador NMPC instável acoplado a um observador estável, de forma a resultar em sistema estável em malha fechada.

De acordo com HENSON (1998), o uso de técnicas NMPC no ambiente industrial depende do desenvolvimento das seguintes áreas :

- Técnicas de modelagem mais eficazes, de forma que o modelo represente o mais fidedignamente possível o comportamento da planta;
- Novas formulações do problema de controle, função objetivo e restrições;
- Estratégias de solução eficientes;
- Aplicações da técnica em escala industrial.

Outro ponto importante abordado por HENSON (1998) é o domínio da formulação do problema de controle a ser resolvido pela estratégia NMPC. Essa formulação pode ser baseada em tempo discreto (BADGWELL, 1997; MANER *et al.*, 1997; POTTMANN e SEBORG, 1997; ZHENG, 1997), ou em tempo contínuo (CHEN e ALLGOWER, 1997; MAYNE e MICHALSKA, 1990, 1991b; PETERSON *et al.*, 1992).

Aproximações lineares de modelos não lineares usados em algoritmos NMPC são estratégias muito comum para resolver problemas de otimização não linear. TRIERWEILER e SECCHI (2000) propuseram um algoritmo NMPC baseado no acoplamento de modelos lineares para representar o comportamento não linear do

processo. DURAIKI *et al.* (2001) apresentaram um controlador NMPC baseado em linearizações locais ao longo da trajetória de predição (LLT). O algoritmo utiliza o modelo não linear para cálculo da predição e minimização da função objetivo, realizando linearizações sucessivas até convergência das ações de controle. O algoritmo apresentou boa performance para controlar sistemas não lineares. Neste contexto, LAWRYNCZUK (2013) propôs três estratégias de linearização para resolver o problema de programação não linear (NLP), o primeiro é uma linearização simplificada ao redor do ponto de operação atual (MPC-NPSL), o segundo consiste no cômputo da predição com o modelo não linear e linearização ao longo da trajetória de predição apenas no início do cálculo da ação de controle (MPC-NPLT), e o último consiste em um algoritmo com cômputo da predição utilizando modelo não linear e linearizações ao longo da trajetória de predição até convergência entre as predições obtidas com o modelo não linear e com o modelo linearizado (MPC-NPLPT). Todas as estratégias utilizaram modelos de Wiener baseado em redes neurais para representar as não linearidades do estado estacionário. Esses modelos não lineares são utilizados para o cálculo da predição e os modelos linearizados são utilizados para resolver o problema de controle como um problema de programação quadrática. Uma desvantagem importante de algoritmos MPC com abordagens de linearizações sucessivas é a qualidade da aproximação, pois afeta muito o desempenho do controlador.

Uma abordagem comum na literatura é transformar o problema NMPC em uma estratégia MPC adaptativa. Essa estratégia consiste em multiplicar a parte dinâmica linear do modelo pelo valor do ganho estático corrente, o qual é calculado em tempo real (SEYAB e CAO, 2006), resultando em um modelo adaptativo às condições operacionais lidas da planta no início de cada cálculo do controlador, além de manter a estrutura do controlador como um algoritmo clássico de MPC.

Uma área importante de estudo das técnicas NMPC é a elaboração de estratégias de solução do problema de otimização não linear, principalmente, quando se refere ao uso da técnica em tempo real, no qual a solução deve ser robusta e obtida dentro da frequência de atuação do controlador. Neste contexto, DIEHL *et al.* (2005) apresentaram uma estratégia de iteração em tempo real, em que apenas uma iteração QP ou Newton é realizada para resolver o problema NLP. Esta estratégia demonstrou robustez e performance satisfatória para aplicações industriais. Buscando esses objetivos, LONG *et al.* (2006) propuseram a aplicação de um método de otimização global e determinístico. A estratégia foi testada com um exemplo clássico da literatura, CSTR de Van de Vusse, e os resultados demonstraram-se melhores, em termos de estabilidade e de tempo computacional, que os apresentados por técnicas que buscam mínimos locais. Este fato sugere o emprego dessa abordagem em problemas de tempo real.

ZAVALA e BIEGLER (2009) propuseram uma abordagem explorando as propri-

idades dos parâmetros presentes na formulação de um problema de controle ótimo (OCP), de forma a representar a solução ótima rigorosa usando análise de sensibilidade da estrutura NLP. PIRNAY *et al.* (2012) apresentaram resultados significativos ao usar critérios de sensibilidade do problema não linear acoplado com métodos de busca em linha.

DONES *et al.* (2010) propuseram uma estratégia multimodelos, na qual o NMPC seleciona o melhor modelo de ordem reduzida para prever a dinâmica do processo, de acordo com a condição operacional vigente. Ou seja, o controlador seleciona modelos de maior complexidade que garantem robustez e eficácia quando a dinâmica é rápida e seleciona modelos de menor complexidade quando a dinâmica é lenta. Além disso, o controlador tem o compromisso de escolher modelos que possam ser viáveis em aplicações de tempo real, mesmo que a dinâmica seja rápida e necessite de modelos mais complexos.

Visando obter estratégias de solução eficiente, MANENTI (2011) propôs uma metodologia de seleção do método de otimização e de resolução de equações algébricas diferenciadas mais adequado para o problema em questão. Dessa forma, o problema é resolvido com a estratégia de solução mais eficiente para suas características.

O desempenho de algoritmos de controle preditivo depende da capacidade do modelo em descrever o comportamento da planta. Neste contexto, estratégias de NMPC têm uma vantagem importante, pois a estrutura do modelo permite descrever o comportamento não linear do estado estacionário da planta, (BLOEMEN *et al.*, 2001), (CERVANTES *et al.*, 2003b), (GÓMEZ *et al.*, 2004), (LAWRYNCZUK, 2010), (PENG *et al.*, 2011).

Estratégias de NMPC consistem na solução de problemas de otimização não linear (NLP) em cada instante de tempo, ocasionando grande esforço computacional. Portanto, o grande desafio para aplicar algoritmos NMPC em unidades industriais é o tempo computacional necessário para resolver o problema NLP sem atrasos que possam degradar a performance do controlador e possivelmente causar problemas de instabilidade no processo. Essa dificuldade originou a proposição de diversas abordagens. Como por exemplo, YANG e BIEGLER (2013) apresentaram um algoritmo que resolve o problema NLP *offline* em um único passo, obtendo a matriz de sensibilidade do problema NLP, que em conjunto com a condição operacional da planta, são utilizados para resolver o problema de controle *online*. Esse algoritmo foi denominado de *advanced multi-step* NMPC e, ao ser comparado com o tradicional NMPC apresentou uma redução significativa no tempo computacional em dois estudos de caso, um CSTR e uma coluna de destilação de separação propano-propileno. LOPEZ-NEGRETE *et al.* (2013) aplicaram essa estratégia em dois problemas de processo de larga-escala.

Um dos pontos de ressalva no uso de controladores não lineares é a sintonia

do controlador, ou seja, a determinação dos pesos da função objetivo. Visando uma melhor seleção desses parâmetros e não por tentativa e erro, VALLERIO *et al.* (2014) sugeriu uma abordagem de sintonia baseada em critérios de otimização multiobjetivo, onde um problema de controle ótimo, similar ao problema do NMPC, é resolvido, obtendo como solução o melhor conjunto de pesos para o controlador cumprir seus objetivos. O autor aplicou a metodologia em dois estudos de caso, CSTR de Van de Vusse e a planta de Tennessee-Eastman, e obteve resultados promissores, sugerindo o emprego da estratégia na sintonia de NMPC's aplicados em outros processos industriais.

BIEGLER *et al.* (2014) propuseram um algoritmo NMPC que leva em consideração critérios econômicos na formulação da função objetivo do controlador, através da adição de um termo de custo à função. Neste algoritmo, os autores propuseram uma função de regularização para o termo de custo, que garante a estabilidade do controlador no estado estacionário ótimo. Além disso, eles propuseram uma metodologia que se utiliza do método de programação linear (LP) para definir os multiplicadores e do método de programação quadrática (QP) para definir as derivadas direcionais, de forma a acelerar a busca do ótimo pelo algoritmo de otimização (NLP). Essa abordagem foi aplicada em um reator CSTR e obteve bons resultados.

Visando reduzir o custo computacional, BIEGLER *et al.* (2015) mostraram uma eficiente metodologia para análise de sensibilidade de problemas não lineares (NLP), capaz de reduzir de 2 a 3 vezes o tempo computacional gasto em abordagens tradicionais.

Seguindo a linha de estratégias de solução para algoritmos de controle preditivo não linear, MARTI *et al.* (2015b) formularam uma estratégia de solução para o problema de otimização de larga escala, através de subproblemas menores, de forma a serem resolvidos iterativamente, utilizando programação estocástica multi-estágio fundamentada em critérios de robustez até a obtenção da solução do problema completo. Nesta estratégia a incerteza do modelo, erro de modelagem, é descrita por cenários que são resolvidos de forma eficiente computacionalmente. Porém, o tamanho do problema de otimização cresce com o tamanho do horizonte de predição e com o número de cenários previstos. Os autores aplicaram a estratégia em dois estudos de caso, um reator de polimerização e uma planta de Hidrodessulfurização (HDS), e os resultados obtidos demonstraram que o método proposto é mais rápido e tem menor consumo de memória para resolver problemas com não linearidades mais fracas, enquanto que problemas com não linearidades mais fortes tiveram resultados piores, isto é, maior tempo de execução que métodos centralizados, ou seja, que resolvem o problema com o escopo completo.

KHANI e HAERI (2015) propuseram um NMPC que se utiliza de modelos line-

ares baseados em incerteza para representar processos não lineares. Dessa forma, o problema de controle não linear é transformado em um problema de controle linear robusto (RMPC). Entretanto, apesar de reduzir o esforço computacional, o RMPC leva para uma solução subótima do problema. Nessa busca por estabilidade, MARTI *et al.* (2015a) propuseram uma abordagem baseada em múltiplos modelos lineares para representar o comportamento não linear do processo. Nessa proposta, o algoritmo é dividido em duas camadas, uma superior, na qual é resolvido *offline* um problema de controle ótimo com horizonte infinito, e uma inferior, na qual é resolvido *online* um problema de controle ótimo de um sistema híbrido e dentro de um horizonte finito.

ALANGAR *et al.* (2015a) propuseram uma estratégia de identificação de sistemas não lineares, obtendo modelos em espaço de estado baseados em polinômios bem condicionados (PNLSS). Os modelos PNLSS podem ser integrados com largos passos de integração mas sem perda significativa de desempenho, possibilitando com isso, redução no tempo computacional para resolver o problema de controle. O uso de modelos não lineares bem condicionados deu origem a estratégias de controle preditivo que usam uma parcela econômica na função de controle e garantem os critérios de estabilidade propostos por Lyapunov (LEMPC). Essas estratégias demonstram estabilidade em malha fechada na presença de tempo morto e ruídos de processo. Existem diversos trabalhos na literatura sobre performance de EMPC que analisam critérios, como por exemplo, de estabilidade, de redução de tempo computacional e de desempenho econômico em malha fechada quando comparado a estratégias que consideram apenas o estado estacionário como ótimo econômico (ALANGAR *et al.*, 2015b; ELLIS e CHRISTOFIDES, 2015). O LEMPC proposto foi aplicado em reator de leito agitado contínuo (CSTR), ilustrando as vantagens computacionais sem redução significativa no desempenho econômico, quando comparado a modelos baseados em princípios fenomenológicos.

RASHID *et al.* (2016) aplicaram uma combinação ponderada de múltiplos modelos lineares para representar as não linearidades presentes no processo de um forno elétrico. Porém, esta metodologia tem como desafio a determinação dos pesos utilizados na ponderação.

INGA e MARQUARDT (2016b) apresentaram uma revisão de algoritmos NMPC baseados em métodos de solução rápida. Nesse estudo é apresentado os pontos em comum deles, focando nos métodos de resolução e na estrutura de controle utilizada.

Outra linha de pesquisa presente na literatura são os métodos de rápida adaptação. Esses métodos consistem em uma aproximação da solução direta do problema de controle ótimo e baseiam-se na construção de uma análise de sensibilidade das variáveis do problema de controle. A escolha da estratégia de *Fast* NMPC não é trivial, pois as estruturas do problema formulado são similares. Nesse con-

texto, INGA e MARQUARDT (2016a) apresentaram uma revisão e avaliação dos métodos de *Fast* NMPC que existem na literatura, comparando as estruturas de controle de cada um deles, bem como as vantagens e desvantagens de cada método.

EATON *et al.* (2017) propuseram um método com o uso do NMPC acoplado a simuladores com a modelagem rigorosa do processo. Nessa abordagem, quando o modelo linear apresenta um erro de predição que excede uma tolerância, o algoritmo realiza uma nova identificação com dados simulados a partir da condição operacional atual. Enquanto o algoritmo re-identifica o processo, uma nova estrutura NMPC com modelo de ordem reduzida é utilizada, (STAMNES *et al.*, 2008), de forma a manter o processo em controle.

Nessa tese de doutorado, é proposta uma abordagem não linear voltada para estratégias de controle NMPC. O modelo não linear proposto reduz o tempo computacional de busca da solução do problema de controle não linear (NLP), possibilitando o uso em tempo real e, com isso, sua aplicação em plantas industriais. O NMPC proposto foi integrado a uma camada de otimização estacionária (RTO) que se utiliza de modelos estáticos do processo e, em outro estudo de caso, foi integrado a uma camada de otimização dinâmica (D-RTO) que usa modelos dinâmicos rigorosos do processo para definir a trajetória ótima econômica. Os estudos de caso demonstram que: o controlador conseguiu levar a planta para o estado estacionário ótimo sugerido pela camada do RTO e também, conseguiu conduzir a planta através da trajetória ótima proposta pela camada de otimização dinâmica (D-RTO), demonstrando com isso, boa acurácia do modelo proposto em descrever tanto o estado estacionário, quanto a dinâmica do processo.

2.2 Fundamentos da Otimização de processo

O uso de técnicas de Otimização tem muitos desafios, especialmente quando aplicadas em tempo real. Os modelos rigorosos usados para representar o comportamento do processo precisam de muita informação da planta, que nem sempre está disponível. Além disso o uso dessas técnicas em processos industriais está sujeito ao cumprimento de algumas premissas, como por exemplo: Etapa de reconciliação de dados - Em que se garante a reprodução do balanço de massa e energia pelo modelo; Detecção de estado estacionário - Etapa crucial para o sucesso da otimização quando se usa modelos estacionários. Nesse contexto, existem muitos trabalhos que questionam se o uso de modelos estáticos é o melhor caminho para se otimizar plantas industriais, pois existe a possibilidade de a dinâmica influenciar na performance da otimização e, além disso, existe dificuldade em garantir que processos industriais estejam em estado estacionário dado a constância de perturbações à planta. Dessa forma, o uso de técnicas de otimização estacionária levaria à determinação de

subótimos BIEGLER *et al.* (2014).

Estudos recentes sobre otimização dinâmica têm mostrado um significativo ganho de desempenho com formulações de NMPC orientadas economicamente (ZAVALA e BIEGLER, 2009). Algumas vantagens dessa formulação são: rápida rejeição de perturbações; problemas com inconsistências entre modelos, camada de controle e camada de otimização, são evitadas e maior grau de liberdade, pois as variáveis de processo podem ser usadas durante o transiente. Entretanto, essas estratégias são complicadas de serem aplicadas em plantas industriais, devido ao grande esforço computacional necessário para resolver o problema de otimização em uma frequência razoável para implementação no processo. Nesta seção são apresentados alguns conceitos de otimização de processos e sua integração com a camada de controle preditivo.

2.2.1 Estratégia de Otimização Estacionária (RTO)

Nos dias atuais em que o mercado está cada vez mais competitivo, é de extrema importância operar com a maior rentabilidade possível, visando à sobrevivência do negócio. Nesse contexto, ferramentas de otimização tornam-se cada vez mais necessárias no dia-a-dia operacional. Neste cenário, SEBORG *et al.* (2010) definem otimização em tempo real como a obtenção das condições operacionais que maximizam a função objetivo econômica, representativa do lucro operacional da planta. Entende-se como lucro, a receita proveniente da venda dos produtos descontada dos custos com matéria-prima e utilidades.

Um problema de otimização é classificado como sendo do tipo de programação não linear (NLP) quando todas as variáveis de decisão são contínuas e, quando sua função objetivo e/ou restrições são não lineares, Equação 2.56.

$$\max_{\mathbf{u}} (F_{obj}(\mathbf{x}, \mathbf{u}, \beta)) \quad (2.56)$$

Sujeito a:

$$\mathbf{f}(\mathbf{x}, \mathbf{u}, \alpha) = \mathbf{0}$$

$$\mathbf{g}(\mathbf{x}, \mathbf{u}, \alpha) > \mathbf{0}$$

$$\mathbf{x}_{min} < \mathbf{x} < \mathbf{x}_{max}$$

$$\mathbf{u}_{min} < \mathbf{u} < \mathbf{u}_{max}$$

em que F_{obj} é a função objetivo econômica; \mathbf{x} é o vetor com as variáveis da planta; $f(\cdot)$ é a representação do modelo da planta; α os parâmetros de identificação do modelo; $g(\cdot)$ são as restrições operacionais da planta e β os parâmetros de sin-

tonia da função objetivo. Dado que esse problema é de programação não linear (NLP), existem inúmeros algoritmos na literatura. Da classe de programação sequencial quadrática, tem-se, por exemplo: NLPQL (SCHITTKOWSKI, 1985), NPSOL (GILL *et al.*, 1986), VF13AD (POWELL, 1978b), DONLP2 (SPELLUCCI, 2002); Da classe dos otimizadores baseados nas técnicas de ponto interior, tem-se: IPOPT (WAECHTER e CARL, 2014), KNITRO (BYRD *et al.*, 2006), LOQO (BENSON e VANDERBEI, 1998); Dos métodos baseados em gradientes reduzidos generalizados, tem-se: GRG2 (POWELL, 1978a), CONOPT (DRUD, 1994).

Esses algoritmos são de otimização local, ou seja, eles buscam um ponto no qual o valor da função objetivo nele é menor do que todos os valores de função objetivo factível que estejam na região ao seu redor. Esses algoritmos são amplamente utilizados no meio industrial, pois dependem apenas que, a função objetivo e suas restrições sejam diferenciáveis. Ao passo que, os algoritmos de busca global apresentam limitações para aplicação em problemas com grande número de variáveis e restrições, devido ao tempo computacional necessário para serem executados.

De acordo com BIEGLER (2010), a classe de algoritmos de programação quadrática sequencial (SQP) se popularizou como abordagem para solução de problemas de programação não linear, devido à rápida convergência e fácil adaptação para uma grande variedade de estruturas. A estratégia SQP consiste na solução de uma sequência de aproximações de programação quadrática para o problema de programação não linear. A grande vantagem de se usar as aproximações está na existência de algoritmos eficientes de programação quadrática que necessitam de um número reduzido de iterações para convergência (WAECHTER e CARL, 2014). Este fato acelera a determinação do ótimo do problema NLP. Nesse caso, não se pode afirmar que o mínimo é global, isso só seria possível se a função objetivo e a região de busca formada pelas restrições fossem convexas.

- Formulação do algoritmo de programação quadrática sequencial

A fundamentação do método é baseada nas condições de otimalidade de um problema de otimização com restrição, equações de Karush-Kuhn-Tucker (KKT).

Formulação geral do problema:

$$\min_{x \in K} f(x) \tag{2.57}$$

Sujeito a:

$$\begin{aligned} h_j(x) &= 0 & j &= 1, 2, \dots, m \\ g_j(x) &\leq 0 & j &= 1, 2, \dots, p \end{aligned}$$

Reescrevendo em termos da função de Lagrange, tem-se:

$$L(x, \lambda, \mu) = f(x) + \lambda^T h(x) + \mu^T g(x) \quad (2.58)$$

O que leva às condições KKT de primeira ordem:

$$\nabla_x L(x, \lambda, \mu) = \nabla f(x) + \lambda^T \nabla h(x) + \mu^T \nabla g(x) = 0 \quad (2.59)$$

$$h(x) = 0$$

$$g_j(x) = 0 \quad \mu_j \geq 0, \quad j \in \text{restrições ativas}$$

$$g_j(x) < 0 \quad \mu_j = 0, \quad j \in \text{restrições inativas}$$

Aproximando por sucessivos problemas de programação quadrática:

$$\min_{d \in R^*} q(d) = \nabla^T f(x^k) d + \frac{1}{2} d^T H^T(x^k, \lambda^k, \mu^k) d \quad (2.60)$$

$$h(x^k) + \nabla^T h(x^k) d = 0 \quad (2.61)$$

$$g(x^k) + \nabla^T g(x^k) d \leq 0 \quad (2.62)$$

A formulação apresentada pela Equação 2.60 pode ser resolvida por um algoritmo de programação quadrática, cuja próxima iteração pode ser determinada pela Equação 2.63, sendo determinado por um procedimento de busca em linha.

$$x_{k+1} = x_k + \alpha_k d_k \quad (2.63)$$

2.2.2 Integração das camadas de otimização e de controle preditivo multivariável

As camadas de controle e de otimização se utilizam de modelos diferentes. O primeiro geralmente faz uso de modelos empíricos para resolver o problema de controle, facilitando dessa forma a solução do problema e permitindo que o controlador atue em alta frequência. Entretanto, esses modelos não descrevem toda região de operação do processo, portanto é importante o uso de técnicas de otimização que se utilizam de modelos fenomenológicos capazes de descrever fielmente toda a região de operação do processo. Porém, esses modelos são muito mais complexos e difíceis de resolver, resultando em baixa frequência de atuação dessa camada.

A integração entre as camadas é uma tarefa difícil, pois o controlador utiliza modelos empíricos para conduzir a planta até o ótimo sugerido pela camada de

otimização. Algumas vezes, essa tarefa torna-se inviável devido à diferença entre os modelos, resultando em um ponto subótimo alcançado pela planta. Portanto, para evitar esse problema, geralmente adota-se como estratégia a incorporação de uma camada de otimização intermediária que se utiliza da representação estática do modelo empírico utilizado pelo controlador. A formulação do problema de otimização desta camada intermediária, consiste em minimizar a diferença entre os valores de referência alcançados por essa camada com aqueles enviados pela camada de otimização, através da solução de um problema de programação quadrática com restrições.

Nessa conjuntura, WANG *et al.* (2017) propuseram uma estratégia para eliminar erros de modelagem entre as camadas de otimização e controle. Nessa abordagem os autores transformam o sistema de equações diferenciais que representa o comportamento dinâmico do processo em um modelo de equações algébricas não lineares, aplicando-o em ambas as camadas de controle e otimização com o mesmo método e intervalo de discretização.

A pirâmide de automação apresentada na Figura 2.4 ilustra o fluxo de informação que uma planta deve ter para operar de forma otimizada. Todo projeto de otimização em tempo real (RTO) segue essa hierarquia de tomada de decisão, pois camadas mais acima, têm uma visão mais holística do negócio, enquanto que camadas mais abaixo têm informações mais específicas do processo.

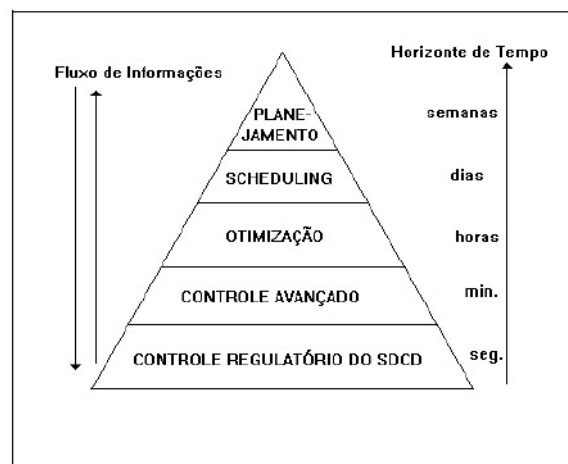


Figura 2.4: Hierarquia de tomada de decisão (Pirâmide da automação) (ZANIN, 2001)

Cada camada da pirâmide é caracterizada pelo tipo de modelo representativo do processo e pelo horizonte de tempo considerado para a respectiva solução (ZANIN, 2001). As camadas ilustradas na figura são:

- Controle regulatório – Representado por controladores PID que foram sintonizados utilizando modelos simples do processo e com frequência de atuação

em segundos.

- Controle Avançado – A função desta camada é rejeitar perturbações que possam ocorrer na planta, de forma a mantê-la estável dentro das restrições operacionais e se possível operando o mais próximo possível da condição ótima. Esta camada utiliza modelos lineares ou não lineares dinâmicos que representam o processo e com frequência de atuação em minutos.
- Camada de Otimização – O foco aqui é determinar o ponto ótimo da unidade, dentro das condições de contorno estabelecidas. Esta camada utiliza modelos rigorosos da planta em estado estacionário (RTO) ou transiente (DRTO). Dada a enorme quantidade de equações a serem resolvidas e da complexidade do sistema, esta etapa é executada com frequência em horas.
- Programação de Produção (*Scheduling*) – Determina o programa de produção da planta, através do uso de modelos simplificados dos processos que a compõem. Considera as seguintes variáveis no problema de otimização: demanda de mercado; disponibilidade de matéria-prima; inventário de produtos, intermediários e finais; situação dos meios de transporte de matéria prima e produtos. Sendo assim, a programação de produção é bastante complexa, o que acarreta uma frequência de atuação de dias.
- Planejamento – Consiste na otimização de todo o parque industrial da companhia. A alocação da matéria prima é função das disponibilidades e eficiências das plantas que compõem o parque industrial e as facilidades de distribuição dos produtos, como: mercado local, regional e exportação (ZANIN, 2001). Os modelos são mais simplificados que os modelos da camada abaixo, porém, o problema é mais complexo, dado ao número de variáveis presentes. O problema de otimização é geralmente resolvido via algoritmo de programação linear (LP) e o horizonte de execução é da ordem de semanas.

A integração entre as camadas de otimização e de controle preditivo pode ser realizada de duas formas, com o alvo da camada de otimização enviado diretamente para a camada de controle preditivo ou com o alvo da otimização enviado a outra camada de otimização dentro do MPC, que utiliza modelos lineares, mais simples e que rodam com frequência em minutos, Figuras 2.5 e 2.6, respectivamente. De acordo com YING e JOSEPH (1999), não há necessidade do uso de três camadas quando o otimizador não linear roda na mesma frequência que o controle preditivo. Caso isso não seja viável, devido à complexidade dos modelos rigorosos, a abordagem de três camadas apresenta as seguintes vantagens:

1. Melhor desempenho econômico. A existência de perturbações entre os ciclos de execução do RTO pode deslocar o ponto ótimo (y^{*nl}, u^{*nl}) determinado por ele (ZANIN, 2001). Portanto, no caso de haver a camada de otimização intermediária rodando na mesma frequência do controlador, ela será retroalimentada com as perturbações ocorridas. Logo, essa otimização intermediária contém os alvos econômicos da solução rigorosa e também informações atualizadas das condições da planta. Essas informações acopladas permitem a condução do processo a uma condição relativamente mais econômica.
2. Melhor desempenho dinâmico. A estratégia em duas camadas deixa o controlador mais lento, no que se refere à rejeição de perturbações, pois os valores calculados $(y^{*nl}$ e $u^{*nl})$ foram obtidos sem considerá-las. Esse fato faz com que o controlador tenha uma atuação mais branda em rejeitá-las. Porém, na existência de uma camada intermediária, os valores (y^{*l}, u^{*l}) já levam em consideração a presença de perturbações quando foram obtidos, de forma que o controlador será mais atuante na rejeição.
3. Eliminação de *offsets* – Durante os entre ciclos do otimizador não linear pode haver perda de grau de liberdade, o que tornaria a obtenção dos alvos (y^{*nl}, u^{*nl}) sugeridos por ele irrealizáveis para o controlador. Além disso, erros de modelagem podem acentuar a presença desses *offsets* nas variáveis controladas. Essas dificuldades são contornadas com a camada intermediária de otimização, que ao rodar na frequência do controlador, já resolve o problema com os graus de liberdade disponíveis no instante. Além disso, o alvo da otimização intermediária, enviado ao problema de controle, foi obtido utilizando o ganho estático do modelo linear do controlador.

A Figura 2.5 ilustra a estrutura de otimização em duas camadas, em que as variáveis controladas (y^{*nl}) e manipuladas (u^{*nl}) são determinadas no otimizador com modelos rigorosos do processo e enviadas à camada de controle preditivo, a qual é responsável por levar a planta para esse ótimo, através de um modelo dinâmico linear, de forma suave, respeitando as restrições operacionais e rejeitando perturbações.

A Equação 2.64 representa a formulação do problema de controle para a estrutura de otimização em duas camadas.

$$\min_{\Delta u(jT), j=1, \dots, n_l} \sum_{i=1}^{n_r} \|W(y_P(iT) - y^{*nl})\|_2^2 + \sum_{j=1}^{n_r} \|S\Delta u(jT)\|_2^2 + \left\| R \left(u_{at} + \sum_{j=1}^{n_l} \Delta u(jT) - u^{*nl} \right) \right\|_2^2 \quad (2.64)$$

em que:

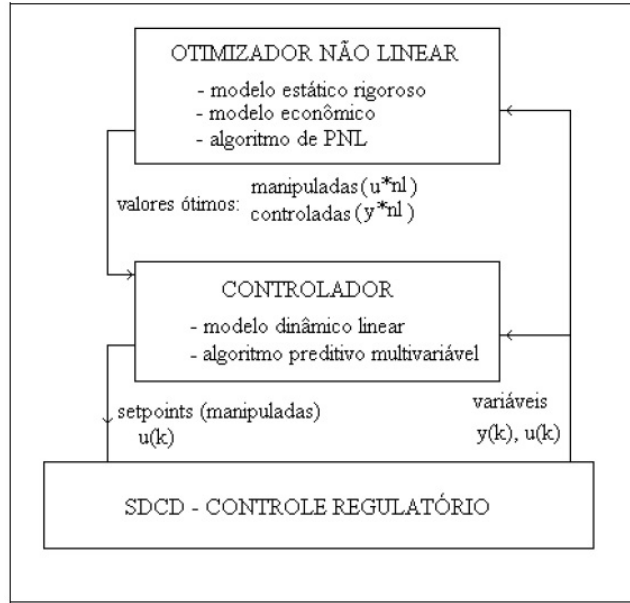


Figura 2.5: Otimização em duas camadas, ou seja, sem otimização na camada do controle preditivo multivariável (ZANIN, 2001).

W, R e S – São parâmetros de sintonia da função objetivo;

u_{at} – Variável manipuladas no instante atual;

Δu – Ações de controle dentro do horizonte de controle nl ;

y_P – São os valores das previsões para as variáveis controladas;

T – Frequência de atuação do controlador;

A Figura 2.6 ilustra a estrutura de otimização em três camadas, estrutura clássica utilizada na maioria das aplicações industriais. A frequência de operação ideal para a camada de otimização não linear deveria ser a mesma de atuação do controlador, porém, dada a complexidade dos modelos fenomenológicos utilizados por ela, isso seria impossível de acontecer. Visando contornar a esse problema, é sugerida uma camada de otimização intermediária, representada pela Equação 2.65, em que é realizada uma otimização na mesma frequência do controlador, porém com modelos lineares estáticos do processo, esses modelos são mais simples, assim como a formulação do problema, baseada no algoritmo de programação linear (LP).

$$\min_{y^*, u^*} |L_y y^T (y^{*l} - y^{*nl})| + |L_u u^T (u^{*l} - u^{*nl})| \quad (2.65)$$

Os valores de y^{*l} e u^{*l} são a solução ótima obtida na otimização intermediária, Equação 2.65, e enviados para a camada de controle preditivo, em que L_y e L_u são parâmetros de sintonia do otimizador. A formulação do problema de controle é similar ao da estrutura com duas camadas, Equação 2.64, porém os alvos de y^{*nl} e u^{*nl} da camada não linear são substituídos pelos alvos da camada linear y^{*l} e u^{*l} .

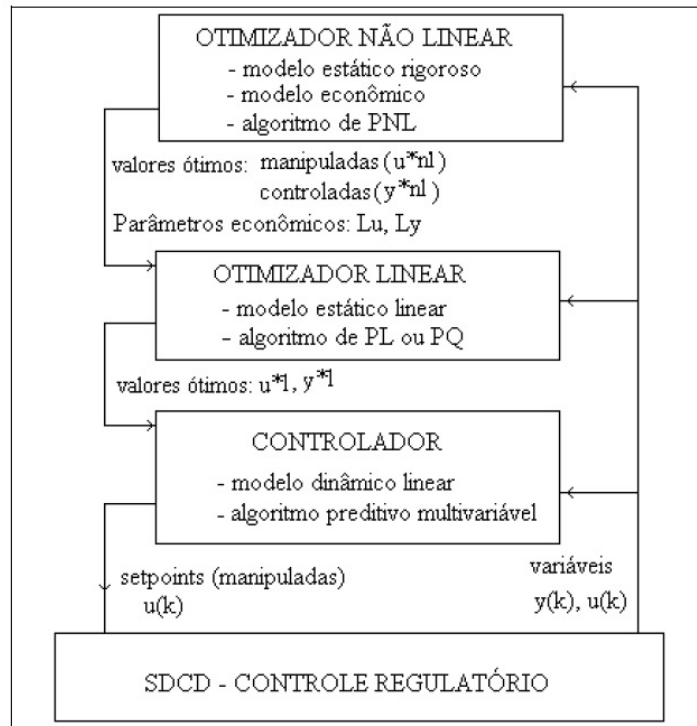


Figura 2.6: Otimização em três camadas, clássica, com camada de otimização na camada de controle (ZANIN, 2001)

2.2.3 Estratégia de Otimização Dinâmica (D-RTO)

Diversos processos industriais têm a lucratividade da operação influenciada pela trajetória das variáveis operacionais ao longo do tempo, isso se deve à existência de perturbações frequentes à planta, o que dificulta uma operação em regime permanente e, por consequência, a utilização de ferramentas de otimização que se utilizam de modelos estacionários do processo (RTO). Neste cenário, é imprescindível que o problema de otimização leve em consideração o impacto da variação temporal das variáveis sobre a função objetivo. Esse fato abre horizonte para o uso de ferramentas de otimização que contemplem a dinâmica do processo durante a obtenção do ótimo da planta (DRTO). Entretanto, o entrave ao uso de técnicas de otimização dinâmica em tempo real é o elevado custo computacional associado à solução do problema de otimização dinâmica. Este esforço está associado ao elevado número de variáveis de decisão decorrente da estrutura matemática do sistema algébrico-diferencial resultante. Objetivando contornar esse problema, SANTOS (2013) propôs o uso do algoritmo de *wavelet* na seleção dos pontos de discretização, de forma a reduzir o número de graus de liberdade do problema de programação não linear. A metodologia proposta foi aplicada em dois estudos de caso, reator semi-batelada isotérmico e reator CSTR, e obteve como resultado uma redução média de 60% no tempo computacional, quando comparada ao domínio completo.

O objetivo deste tópico é descrever essas técnicas de otimização dinâmica, que

consistem em obter a solução de problemas de otimização algébrico-diferenciais (DAOP). Neste contexto, problemas de otimização dinâmica podem ser divididos em duas classes: métodos direto e métodos indireto (EDELBAUM, 1962). A Figura 2.7 ilustra a árvore de métodos aplicáveis a problemas de otimização dinâmica.

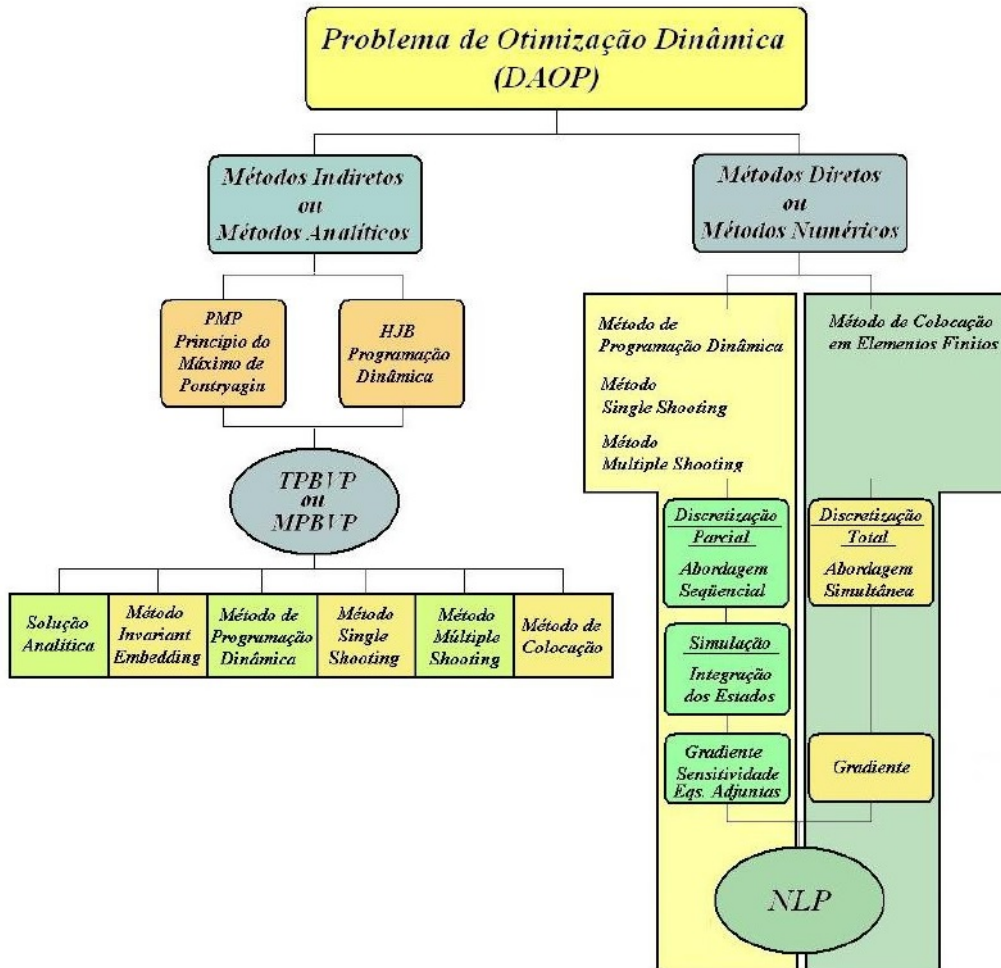


Figura 2.7: Árvore de seleção do método de solução de problemas de otimização dinâmica (DAOP) (ALMEIDA e SECCHI, 2012)

métodos direto

Nesses métodos, o sistema DAOP é total ou parcialmente discretizado em um sistema de equações algébrico-diferenciais ou puramente algébrico, respectivamente, modificando a estrutura do problema, passando de um problema de otimização dinâmica para um problema de programação não linear (NLP). A escolha do método de solução NLP dependerá da dimensão e da natureza do problema (ALMEIDA e SECCHI, 2012). Podem-se subdividir os métodos diretos em dois subgrupos:

1. Abordagem sequencial: Nesta abordagem apenas as variáveis de controle são discretizadas, enquanto as variáveis de estado são obtidas via integração do

sistema algébrico-diferencial (DAE), ou seja, há uma discretização parcial do sistema. A solução do problema é obtida iterativamente em dois passos sequenciais: integração e otimização. Existem alguns algoritmos na literatura para essa classe de problema, dos quais se destacam o de programação dinâmica e os métodos de shooting (*single-shooting* e *multiple shooting*).

- Single-shooting: Nesta variante do método sequencial, o algoritmo sugere uma função de discretização para as variáveis de decisão, essas são usadas para definir o perfil das ações de controle que são utilizadas no ciclo interno de integração. Neste ciclo são calculados os valores dos estados ao longo dos elementos de discretização. Esses valores são necessários para o cálculo da função objetivo e dos gradientes que são fornecidos ao ciclo externo, algoritmo NLP. O algoritmo utiliza as informações da função objetivo e dos gradientes para calcular o conjunto de ações da próxima iteração, o processo se repete até a determinação do perfil ótimo de controle. Esse método é conhecido como caminho viável e está representado na Figura 2.8.

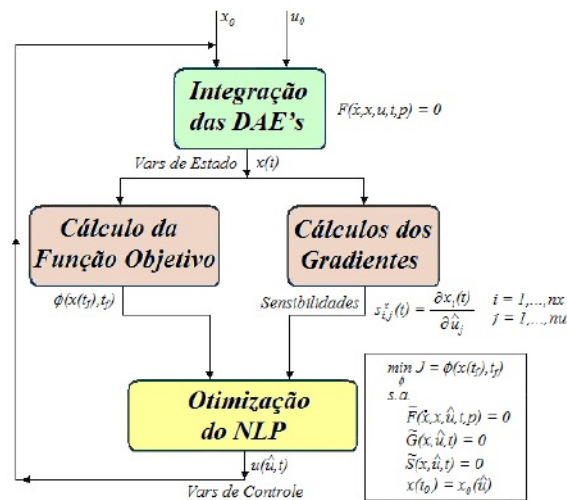


Figura 2.8: Método direto utilizando abordagem single-shooting (ALMEIDA e SECCHI, 2012).

- Multiple shooting: Nesta variante do método sequencial, os valores iniciais das variáveis de estado, em cada intervalo de discretização, são considerados como graus de liberdade de otimização adicionais. Nesta abordagem é possível paralelizar a integração de cada elemento discreto, acrescentando restrições de igualdade que garantem a continuidade dos estados entre elementos discretos adjacentes. Para priorizar a condição de continuidade das trajetórias, restrições de igualdade, frente às restrições

de desigualdade, são utilizados critérios de penalização para o cumprimento da viabilidade (*Feasible path*). Esses métodos são considerados híbridos, pois há uma discretização dos estados nos pontos da malha, em acréscimo as variáveis de controle da discretização parcial.

2. Abordagem Simultânea: Nesta abordagem todas as variáveis são discretizadas, as variáveis de controle e as variáveis de estado, obtendo um sistema de equações algébricas não lineares. Nesta formulação, todas as variáveis são de decisão, o que permite a solução do problema NLP, de grande dimensão, simultaneamente à integração do sistema DAE via quadratura numérica. Este método exige menor esforço computacional para resolver problemas de larga escala, pois evita a etapa de integração. Contudo, o otimizador pode encontrar soluções intermediárias que são inviáveis (*infeasible path*). Outro ponto que merece ressalva, é o fato da solução só ficar disponível ao final da otimização, ou seja, fica difícil identificar o efeito das variáveis de otimização na função objetivo, durante as etapas de iteração. Dentre os métodos utilizados nessa abordagem, pode-se citar o método de colocação, diferenças finitas e colocação em elementos finitos.

Métodos indireto

Nesses métodos, o problema de otimização dinâmica é resolvido através dos fundamentos de controle ótimo, com o uso de técnicas de cálculo variacional. Estes métodos são analíticos, por utilizar as condições de otimalidade para transformar um problema DAOP em um problema de duplo valor (TPBVP – *Two Point Boundary Value Problem*) (ALMEIDA e SECCHI, 2012). Há basicamente dois métodos que usam essa abordagem:

- Programação Dinâmica (BELLMAN, 1957).

Baseado no princípio de otimalidade de Bellman e na solução das equações de Hamilton-Jacobi-Bellman (HJB). A formulação de HJB aplica o princípio de otimalidade de Bellman para transformar o problema de otimização da função objetivo escalar J em um sistema de equações diferenciais parciais (PONTRYAGIN *et al.*, 1962). Este teorema parte do princípio de que o hamiltoniano de um sistema contínuo sujeito a restrições de igualdade deve ser minimizado para um conjunto de variáveis de decisão.

A formulação geral do problema de otimização dinâmica:

$$\min_{x(t), u(t), t_f, p} J(x(t), u(t), t, p) = \phi(x(t_f), t_f) + \int_{t_0}^{t_f} \varphi(x(t), u(t), t, p) dt \quad (2.66)$$

Sujeita a:

$$F(\dot{x}(t), x(t), u(t), t, p) = 0 \quad \forall t \in T \quad (2.67)$$

Definição do Hamiltoniano:

$$H(\dot{x}(t), x(t), u(t), \lambda(t), t, p) = \Phi(x(t), u(t), t, p) + \lambda(t)^T F(\dot{x}(t), x(t), u(t), t, p) \quad (2.68)$$

A partir das condições de otimalidade, pode-se determinar $u(t)$, $\lambda(t)$ e $x(t)$:

$$0 = H_u(t) = \varphi_u(t) + \lambda(t)^T + F_u(\dot{x}, x, u, t, p) \quad (2.69)$$

$$-\dot{\lambda}(t)^T = H_x(t) = \varphi_x(t) + \lambda(t)^T F_x(\dot{x}, x, u, t, p) \quad (2.70)$$

$$\dot{x} = H_\lambda(t) = F_x(\dot{x}, x, u, t, p) \quad (2.71)$$

Considerando que:

$\lambda(t)$ - São os multiplicadores de Lagrange.

H_λ - É o gradiente de H em relação à $\lambda(t)$.

$H_x(t)$, $\Phi_x(t)$, $F_x(t)$ - São os gradientes de $H(t)$, $\Phi(t)$, $F(t)$, respectivamente, em relação à $x(t)$.

$H_u(t)$, $\Phi_u(t)$, $F_u(t)$ - São os gradientes de $H(t)$, $\Phi(t)$, $F(t)$, respectivamente, em relação à $u(t)$.

Sendo $H_u(t) = \frac{\partial H}{\partial u} = 0$ a condição necessária de 1ª ordem de otimalidade.

As condições de contorno são dadas por:

$$\begin{aligned} x(0) &= x_0 \\ \lambda(t_f) &= \Phi_x^T(t_f) \end{aligned}$$

Este procedimento resulta em um problema TPBVP.

2.3 Estado da arte de técnicas de controle e otimização aplicadas em processos industriais, com ênfase em produção de óleo *offshore*

Produção de óleo *offshore* é uma atividade complexa onde o fluido explorado é transportado desde os poços no leito marinho, passando pelos *risers* e *flowlines* até chegar à planta de processamento no *topside* da plataforma. Essa operação é marcada pela presença de bolsões de gás, denominadas golfadas, que nada mais são do que oscilações no fluxo de vazão de produção. Essas golfadas podem provocar paradas não-programadas na plataforma, principalmente no sistema de compressão de gás da planta. Além das paradas não-programadas, as golfadas prejudicam a eficiência de separação nos vasos de separação gravitacional que existem no início da planta de processamento e servem para separar as correntes de gás, óleo e água. Uma baixa eficiência de separação nesses vasos resulta em grande quantidade de água e sedimentos no óleo (BSW) e grande quantidade de óleo na água descartada (TOG). Grandes quantidades de BSW no óleo processado ocasionam problemas de corrosão nos oleodutos de exportação e nas refinarias. Assim como, grandes quantidades de óleo na água descartada podem resultar em prejuízos econômicos devido a multas aplicadas por órgãos ambientais, além de danos ao meio ambiente. Nesse contexto, o uso de aplicações em tempo real para monitoração, controle e otimização torna-se importante, pois essas ferramentas podem mitigar os impactos citados na planta de processamento, através de maior disponibilidade do sistema, menor risco ambiental e, havendo margem, maior rentabilidade da planta.

SKOFTELAND e GODHAVN (2003a) apresentaram os resultados da implantação de um controlador antigolfadas em uma plataforma flutuante do tipo TLP (Tension-Leg Platform) em Heidrum. Esse controle baseia-se em um controlador de pressão na cabeça do *choke* com um controlador de vazão atuando no *choke* de produção. Esses controladores foram sintonizados utilizando os modelos dinâmicos de escoamento *slug* no *riser*, propostos por STORKAAS e SKOGESTAD (2002) e SKOFTELAND e GODHAVN (2003b). O esquemático do controlador é apresentado na Figura 2.9.

Uma das formas de otimizar a produção de óleo e gás em plataforma, consiste em reduzir a pressão na cabeça do reservatório, porém essa ação ocasiona golfadas que podem ocasionar a parada da planta. GODHAVN *et al.* (2005) propuseram a aplicação de técnicas de controle preditivo linear em conjunto com estratégia de controle antigolfadas. Com isso, foi possível trabalhar em pressões menores na cabeça do poço, maximizando a produção e, ao mesmo tempo, evitando patamares de pressão golfantes. Os resultados do trabalho apresentam redução de 8 bar na cabeça do

poço e aumento de 3% na vazão de óleo produzido.

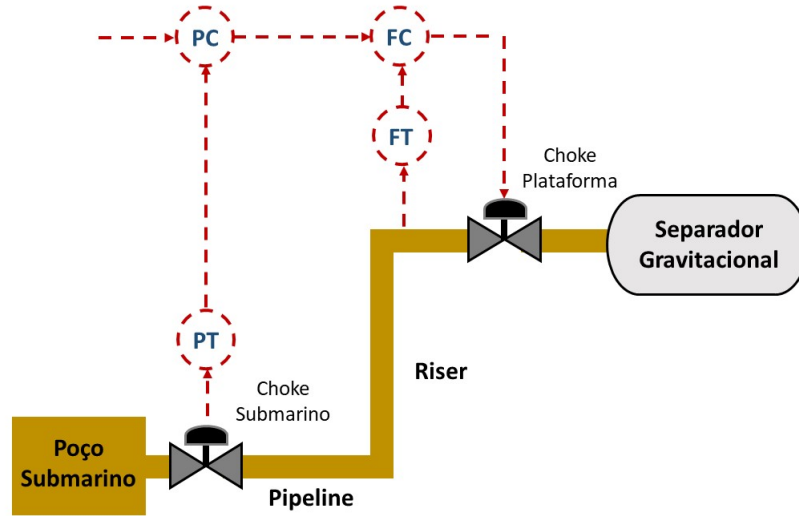


Figura 2.9: Estratégia de controle antigolfada

EIKREM (2006) empregou técnicas de controle *feedback* para estabilizar a injeção de *gas-lift* para a produção de óleo e gás *offshore*.

PLUCENIO (2010) apresentou uma estratégia multi-modelos lineares, distribuídos ao longo de todo o riser, de forma a representar as características não lineares do escoamento multifásico no poço e no riser, em presença de injeção de *gas-lift*. Esses modelos lineares foram utilizados em técnicas de controle preditivo linear (MPC).

VOLCKER *et al.* (2011) aplicaram técnicas de NMPC utilizando o algoritmo de programação quadrática sequencial (SQP) em conjunto com técnicas de *single shooting* para maximização da receita de exploração de óleo na fase pós-surgente do poço. A formulação do problema de otimização é apresentada pela Equação 2.72, em que a equação diferencial representa o balanço de massa do poço e os graus de liberdade da otimização são a pressão de fundo do poço e a taxa de injeção de água no reservatório, com frequência de atualização a cada 30 dias. O resultado obtido ilustra um aumento de 10% na receita para um horizonte de 360 dias, quando comparado a um horizonte de 220 dias com as variáveis de decisão sendo mantidas constantes. Esse aumento de receita é explicado pela redução do custo de produção, ocasionado pela queda de 10% do *watercut* produzido.

$$\min_{x(t), u(t)} \phi = \int_{t_0}^{t_f} J(x(t), u(t)) dt \quad (2.72)$$

Sujeita a:

$$\begin{aligned} \frac{d}{dt}g(x(t)) &= f(x(t), u(t)), & x(t_0) &= x_0 \\ c(u(t)) &\geq 0 \end{aligned}$$

RIBEIRO (2012) utilizou modelos lineares para representar o processo de exploração de óleo e gás *offshore*, desde o poço até o separador gravitacional da planta de processamento primário de óleo. Esses modelos foram utilizados em estratégias de controle preditivo linear. Apesar da característica não linear do processo, a estratégia apresentou bons resultados para a faixa de operação do controlador.

SALAHSHOOR *et al.* (2013a) propuseram um NMPC baseado em modelo de rede neuronal para estabilização em tempo real de instabilidades causadas pelos efeitos da interação entre a vazão de injeção de *gas-lift* e o fluido multifásico vindo do reservatório. Os resultados ilustram bom desempenho do algoritmo em controlar a pressão na cabeça do poço, mitigando os impactos das golfadas na vazão de óleo produzida, através de manipulação da abertura da válvula *choke* e da vazão de injeção de *gas-lift*.

A maioria dos poços de produção de óleo e gás no Brasil são explorados via métodos de elevação artificial, no qual o método de injeção de *gas-lift* figura como uma das principais tecnologias. Neste cenário, o uso de técnicas de otimização que maximize a produção de óleo e gás e, ao mesmo tempo, respeite as restrições de operação da planta é de extremo valor. Seguindo esse foco, TEXEIRA (2013) apresentou duas formulações para o problema de otimização, uma baseada na maior rentabilidade da operação e a outra baseada na máxima produção de óleo.

Além disso, o autor aplicou técnicas de otimização tradicionais ao problema em estudo, obtendo como resultado um bom desempenho para o método de programação quadrática sequencial com função de regularização. Porém, essa técnica se mostrou bastante dependente da estimativa inicial. Visando contornar esse problema, o autor propôs uma abordagem híbrida, na qual a estimativa inicial é obtida através da linearização do problema de otimização, através do método das estruturas especiais (SSM), e posterior solução via método de programação linear inteira mista (MILP). Após essa etapa, o problema de otimização é resolvido via SQP, utilizando como estimativa inicial o ótimo encontrado na etapa anterior MILP-SSM. Os resultados dessa nova abordagem foram superiores às outras testadas.

WILLERSRUD e IMSLAND (2013) propuseram uma abordagem, na qual a camada de otimização econômica é resolvida junto da camada do problema de controle do NMPC. Essa estratégia foi aplicada no problema esquemático da Figura 2.10, em que o escopo do controlador consiste de 3 variáveis controladas (Pressão no manifold de produção; pressão no separador e vazão de óleo produzido) e 2 variáveis manipu-

ladas (abertura da válvula *choke* do poço 1 e abertura da válvula *choke* do poço 3). Segundo o autor, a solução da otimização econômica e do problema de controle em uma única camada acarreta vantagens quando comparada a abordagem de duas camadas, são elas: modelo único a ser atualizado, rejeição imediata das perturbações e otimização econômica durante o transiente.

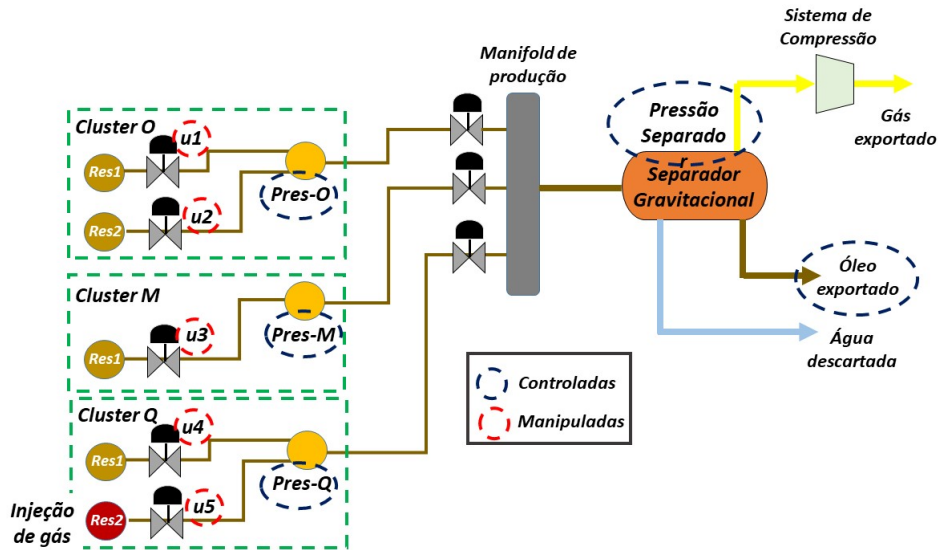


Figura 2.10: Fluxograma de exploração de óleo e gás via injeção de *gas-lift*

A injeção de *gas-lift* em poços de produção de petróleo visa aumentar a produção, porém causa instabilidades no escoamento do fluido proveniente do poço. Objetivando solucionar esse problema, SALAHSHOOR *et al.* (2013b) propuseram técnicas de controle preditivo não linear, utilizando modelos de redes neurais adaptativos para representar o comportamento do processo e, por consequência, prever a ocorrência das instabilidades durante a exploração do poço. Os resultados obtidos pela aplicação dessa abordagem para tratar os problemas de exploração de óleo e gás com injeção de *gas-lift* foram promissores.

Processos de exploração de óleo e gás apresentam características não lineares entre as variáveis operacionais. Visando aplicar técnicas NMPC nesse estudo de caso, DAEHLEN *et al.* (2003) propuseram um algoritmo de otimização livre de derivadas (DFO) e acoplado a técnicas de programação quadrática (SQP). Essa proposição foi aplicada a um separador óleo-gás submerso e teve seus resultados comparados com técnicas NMPC tradicionais, do tipo *single-shooting*. Os resultados apresentaram maior robustez numérica sem aumento no custo computacional, quando comparado às técnicas que usam derivadas.

JAHANSHAH e SKOGESTAD (2015) propuseram um controlador *antislug* baseado em modelos empíricos obtidos através de identificação de dados de planta. O controlador usou modelos não lineares para descrever as não linearidades do pro-

cesso, mas essa solução não apresentou boa performance na presença de tempo morto ou na existência de erros de modelagem.

SHAO *et al.* (2016) apresentaram um controlador orientado por modelos de equações diferenciais ordinárias (ODE) de ordem elevada para descrever as dinâmicas de injeção de *gas-lift* e o fenômeno de *casing-heading*. Os resultados ilustram que o controlador estabiliza em malha fechada um sistema instável em malha aberta, sem ocasionar redução na vazão de produção de óleo. O controlador usa a pressão no fundo do poço como variável controlada e o *choke* de produção como variável manipulada.

RIBEIRO *et al.* (2016) aplicaram um controle preditivo multivariável com modelo linear (MPC) para controlar a produção de óleo e manter as quantidades de água no óleo (BSW) e de óleo na água (TOG) dentro das especificações. De acordo com os autores, a não linearidade do processo faz com que o controlador só tenha bom desempenho nas regiões próximas ao ponto operacional no qual os modelos foram identificados. As grandes variações nos fluxos de entrada e as não linearidades do processo dificultam o controlador de operar por grandes períodos de tempo, pois há perda de desempenho, dependendo da região de operação e da característica de perturbação.

JAHANSHASHI e SKOGESTAD (2017) propuseram quatro estratégias de controle *feedback* para mitigar regimes de fluxo golfante em processos de produção de óleo *offshore*, utilizando como variáveis controladas as pressões no fundo do poço e no *topside*. São elas : (1) Linearizações no *feedback* das variáveis de saída; (2) Controlador com modelo interno (IMC) e ganho *scheduling*; (3) Controlador PI com ganho adaptativo baseado no ganho estático; (4) Controlador *feedback* com estimação de estado por observador não linear de ganho alto. Como resultado do trabalho, os autores concluíram que controladores não lineares baseados em estratégias de ganho *scheduling* mostraram-se mais robusto e mais eficientes computacionalmente do que controladores não lineares baseados em modelos fenomenológicos.

GEREVINI *et al.* (2018) aplicaram uma estratégia NMPC baseada em linearizações locais ao longo da trajetória de predição (LLT). O controlador usou o modelo *Fast Offshore Well* (FOWM) para representar o comportamento não linear do processo, tendo como escopo de controle a injeção de *gas-lift* e a abertura da válvula *choke* como variáveis manipuladas e a pressão na cabeça do poço como variável controlada. Os resultados do trabalho ilustram um ganho na produção de óleo de 9.0%

MIYOSHI *et al.* (2018) aplicaram um algoritmo de controle preditivo não linear (NMPC), utilizando modelos de Hammerstein com formulação em espaço de estado para descrever o comportamento da vazão de produção de óleo em função da vazão de injeção de *gas-lift*. Os resultados mostram que o algoritmo consegue estabilizar

o processo.

SUWARTADI *et al.* (2018) propuseram um preditor baseado na matriz de sensibilidade das variáveis de controle, denominado de "step-advanced" NMPC. O método foi aplicado na otimização de uma rede de poços de injeção de *gas-lift* e comparado com abordagens tradicionais de NMPC.

A pesquisa bibliográfica presente neste tópico demonstra que existe espaço para novas contribuições às técnicas NMPC aplicadas em plantas offshore: (1) Como resolver o problema não linear em tempo computacional razoável, de forma que as condições operacionais utilizadas para obter a solução do problema de controle ainda sejam válidas; e (2) Como obter um modelo não linear que descreva bem o comportamento não linear da planta. Sendo assim, o trabalho visa contribuir na proposição de uma metodologia de solução rápida para algoritmos NMPC baseada em modelos analíticos que descrevem o processo, ou seja, sem a necessidade da etapa de integração do sistema de ODEs que está presente na maioria das estratégias de NMPC.

O NMPC proposto foi aplicado para maximizar a produção de óleo em plataformas *offshore*, além de garantir as especificações de processo dentro dos limites de operação, como por exemplo, quantidade de água e sedimentos no óleo (BSW) e quantidade de óleo na água (TOG). Outra vantagem importante dessa estratégia é mitigar os impactos ocasionados por regimes de fluxos golfantes, estabilizando a planta de processamento e conduzindo-a de forma suave até uma condição operacional ótima. O escopo do controlador consiste em: variáveis manipuladas - abertura da válvula *choke* de produção, vazão de injeção de *gas-lift* e nível de interface do vaso de separação gravitacional; variáveis controladas - vazão de produção de óleo, quantidades de água e sedimentos no óleo (BSW) e quantidade de óleo na água descartada (TOG).

Capítulo 3

Metodologia Proposta

Esta seção é dedicada a descrever a metodologia de NMPC proposto, de rápida solução computacional, e sua integração com uma camada de otimização estacionária (RTO) e uma camada de otimização dinâmica (DRTO).

3.1 Formulação do problema de controle

O NMPC é baseado na solução de um problema de controle ótimo não linear discreto (NOCP), sendo formulado pela Equação 3.1.

$$\begin{aligned} \min_{\mathbf{u}} J(\mathbf{u}) = & \sum_{k=1}^{H_p} [\mathbf{y}^{SP}(t_k) - \mathbf{y}(t_k)]^T \mathbf{W} [\mathbf{y}^{SP}(t_k) - \mathbf{y}(t_k)] + \sum_{k=1}^{H_c} \Delta \mathbf{u}^T(t_k) \mathbf{S} \Delta \mathbf{u}(t_k) + \\ & \sum_{k=1}^{H_c} [\mathbf{u}^{SP}(t_k) - \mathbf{u}(t_k)]^T \mathbf{R} [\mathbf{u}^{SP}(t_k) - \mathbf{u}(t_k)] \end{aligned} \quad (3.1)$$

Sujeito às restrições:

$$\mathbf{y}(t_k) = f^{NL}(\mathbf{u}(t_k), \mathbf{d}(t_k), \mathbf{y}(t_0), t_k), \quad t_k \in [t_1, t_{H_p}] \quad (3.2)$$

$$\mathbf{u}_{min} \leq \mathbf{u}(t_k) \leq \mathbf{u}_{max} \quad (3.3)$$

$$\mathbf{y}_{min} \leq \mathbf{y}(t_k) \leq \mathbf{y}_{max} \quad (3.4)$$

Sendo H_P o horizonte de predição, H_C o horizonte de controle, W é a matriz diagonal positiva semidefinida dos pesos das variáveis controladas, R é a matriz diagonal positiva semidefinida dos pesos das variáveis manipuladas, S é a matriz diagonal positiva semidefinida dos fatores de supressão de movimento das variáveis manipuladas, u^{sp} e y^{sp} são os valores de referência das variáveis manipuladas e das variáveis controladas, respectivamente, oriundas da camada de otimização, $\mathbf{u}(t_k) \in \mathfrak{R}^{n_u}$ e

$\mathbf{d}(t_k) \in \mathfrak{R}^{n_d}$ são as ações de controle e as perturbações, respectivamente, com $\mathbf{u}(t_k)$ descrita por uma função constante por partes. Nesse trabalho, todas as perturbações são consideradas medidas mas, algumas vezes, plantas industriais apresentam perturbações não medidas importantes. Neste cenário, o uso de técnicas, como por exemplo, filtro de Kalman (HUANG *et al.*, 2012) pode estimar os efeitos dessas perturbações nas variáveis controladas, $\mathbf{y}(t_k)$. O modelo não linear é descrito na próxima seção.

As Equações 3.1 até 3.4 caracterizam a formulação do NMPC, sendo a Equação 3.2 a principal novidade, com modelo interno analítico, descrito a seguir pelas Equações 3.6 até 3.9, para descrever o comportamento dinâmico do processo. O NMPC proposto foi comparado com uma formulação NMPC utilizando modelo interno igual ao da planta, Equação 3.5, ou seja, descrito pelas equações algébrico-diferenciais (DAEs) que regem o comportamento fenomenológico da planta. A solução do NMPC com o modelo rigoroso serviu de referência para avaliar o desempenho do NMPC com o modelo não linear proposto, demonstrando redução do custo computacional sem perda de desempenho significativa.

$$F(\dot{\mathbf{x}}(t_k), \mathbf{x}(t_k), \mathbf{y}(t_k), \mathbf{u}(t_k), \mathbf{d}(t_k), t_k) = 0, \quad x(t_0) = x_0; \quad t_k \in [t_0, t_{H_p}] \quad (3.5)$$

Sendo $F(\bullet) \in \mathfrak{R}^{n_x+n_y}$ o sistema de equações algébrico-diferenciais (DAE), $\mathbf{x}(t_k) \in \mathfrak{R}^{n_x}$ são as variáveis de estado, $\mathbf{y}(t_k) \in \mathfrak{R}^{n_y}$ são as variáveis controladas e $\mathbf{u}(t_k) \in \mathfrak{R}^{n_u}$ são as variáveis manipuladas.

O problema NLP foi resolvido utilizando o método do ponto interior (BIEGLER, 2010), com uma diferença importante entre o modelo proposto e a solução de referência, onde o NMPC da solução de referência tem o sistema de equações algébrico-diferenciais integrado via métodos numéricos ou transformado em um sistema de equações algébricas não lineares (NLA) por técnicas de discretização, como por exemplo, colocação ortogonal em elementos finitos. Na abordagem proposta, o sistema de equações algébricas não lineares proposto (NLA proposto) descreve de forma eficaz o sistema de equações algébrico-diferenciais original (DAEs) com o cômputo analítico do gradiente e da Hessiana de forma rápida, tornando a solução do problema NLP bem mais eficiente.

3.2 Determinação do modelo não linear

O grande desafio na aplicação de técnicas NMPC está no desenvolvimento de modelos que representam o processo sem grande custo computacional. A etapa de desenvolvimento do modelo é muito importante porque o desempenho do controla-

dor depende de quão capaz é o modelo em descrever o comportamento da planta. Conforme discutido no Capítulo 2, existem diversos modelos não lineares na literatura que podem ser usados em algoritmos NMPC. Modelos de Hammerstein que têm estruturas orientadas por blocos, composto de bloco com modelo não linear, que mapeia as regiões não lineares do estado estacionário do processo, e outro bloco com modelo linear para representar o comportamento dinâmico. Existe uma vantagem importante em estratégias MPC com modelo Hammerstein, pois a parte estática do modelo compensa as não linearidades do processo (BLOEMEN *et al.*, 2001; CERVANTES *et al.*, 2003b; GÓMEZ *et al.*, 2004; LAWRYNCZUK, 2010; PENG *et al.*, 2011).

Nesse trabalho, uma abordagem multiparamétrica para representar as não linearidades do processo foi proposta. Entretanto, diversas outras estruturas podem ser usadas na Equação 3.2, como por exemplo, função contínua linear por partes (CERVANTES *et al.*, 2003a), *spline* cúbica (NORQUAY *et al.*, 1999), *wavelets* (AADALEESAN *et al.*, 2008), combinação linear de funções bases (GOMES *et al.*, 2004) e redes neurais artificiais (LAWRYNCZUK, 2007).

A Equação 3.6 mostra o modelo proposto usado para representar o processo, sendo que a Equação 3.7 é a estrutura multiparamétrica que representa as condições do estado estacionário, mais detalhes no apêndice A, e a Equação 3.9 é a estrutura analítica que representa o comportamento dinâmico, mais detalhes no apêndice B. Esse algoritmo NMPC usando o modelo analítico proposto na solução do problema NLP é comparado com uma abordagem MPC adaptativa.

A estratégia MPC adaptativa abordada no estudo utiliza ganho estático adaptativo calculado nas condições operacionais lidas pelo controlador no início do ciclo de controle. A função não linear para representar o ganho estático adaptativo foi a mesma utilizada pelo NMPC com o modelo proposto. A principal diferença entre essas abordagens consiste no fato de que a estratégia NMPC considera o estado estacionário não linear durante a solução do problema de controle, resultando em um problema NLP, enquanto na abordagem linear adaptativa, o comportamento não linear é descrito apenas para atualizar o ganho estático no início do ciclo de controle, permanecendo constante durante a solução do problema quadrático. Em outras palavras, o modelo linear assume um comportamento adaptativo a depender das condições operacionais lidas no início do ciclo de controle, como por exemplo, inversões de ganho ou mudança de ordem de grandeza. Porém, uma desvantagem dessa estratégia é a não atualização ao longo do cálculo da trajetória de predição, ou seja, a atualização é feita apenas no início do ciclo e não durante a solução do problema de controle.

$$\mathbf{y}(t) = \mathbf{y}^0 + [\mathbf{y}^{ss}(\mathbf{u}, \mathbf{d}) - \mathbf{y}^0] \otimes \mathbf{f}(t) \quad (3.6)$$

$$y_j^{ss}(\mathbf{u}, \mathbf{d}) = \prod_{k=1}^{n_u} \sum_{i=0}^{n_1} C_{i,k,j}(\mathbf{d}) (u_k)^i \quad (3.7)$$

$$C_{i,k,j}(\mathbf{d}) = \prod_{l=1}^{n_d} \sum_{m=0}^{n_2} \alpha_{i,k,j,m,l} (d_l)^m \quad (3.8)$$

$$f_j(t) = 1 - \exp \left[\frac{-\varepsilon_j (t - \tau_{d_j})}{\tau_j} \right] \left\{ \cosh \left[\frac{\sqrt{\varepsilon_j^2 - 1}}{\tau_j} (t - \tau_{d_j}) \right] + \frac{\varepsilon_j}{\sqrt{\varepsilon_j^2 - 1}} \sinh \left[\frac{\sqrt{\varepsilon_j^2 - 1}}{\tau_j} (t - \tau_{d_j}) \right] \right\} \quad (3.9)$$

Sendo $j = 1, \dots, n_y$, $C_{i,k,j}$ e $\alpha_{i,k,j,m,l}$ os parâmetros dos polinômios de graus n_1 e n_2 , respectivamente, \otimes é o produto de Hadamart (definição no apêndice C), $\mathbf{y}(t) \in \mathfrak{R}^{n_y}$ são as variáveis controladas, $\mathbf{y}^0 \in \mathfrak{R}^{n_y}$ são os valores iniciais das variáveis controladas, $\mathbf{y}^{ss} : R_u^n \times R_d^n \rightarrow R_y^n$ representa o estado-estacionário das variáveis controladas como função das variáveis manipuladas, enquanto $\mathbf{f}(t) \in \mathfrak{R}^{n_y}$ descreve o comportamento dinâmico do processo. É importante ressaltar que a estrutura da Equação 3.6 permite obter de forma rápida o gradiente e a Hessiana analiticamente, reduzindo com isso o esforço computacional para obter a solução do problema NLP.

A metodologia usada para obter o modelo descrito nas Equações 3.6 a 3.9 pode ser organizada em duas etapas: (1) Seleção da estrutura mais adequada para descrever o comportamento dinâmico do processo através de testes de identificação, usando funções de primeira e segunda ordem, com e sem tempo morto, que minimiza a soma do quadrado dos erros calculada pela diferença entre os valores de planta e do modelo em cada instante de tempo, Equação 3.10. (2) Uma função multi-paramétrica foi proposta para representar a não linearidade do estado-estacionário, onde apenas os dados de estado estacionário foram utilizados para obter os parâmetros do modelo. Além disso, determinou-se o procedimento de testes degraus nas variáveis manipuladas, capazes de gerar dados suficientes para descrever a não linearidade do processo.

$$\arg \min_{\theta} \sum_{k=1}^{H_p} (Error(t_k))^2 \quad (3.10)$$

$$Error(t_k) = y^P(t_k) - y(t_k), \quad t_k \in [t_1, t_{H_p}] \quad (3.11)$$

Em que θ são parâmetros do modelo, $\mathbf{y} \in \mathfrak{R}^{n_y}$ são as variáveis controladas estimadas

pelo modelo e $\mathbf{y}^P \in \mathfrak{R}^{n_y}$ são as variáveis da planta.

Processos de identificação de modelos não lineares são desafiadores, pois consistem em um problema de otimização, possivelmente não-convexo, para ser resolvido, sendo portanto, difícil de garantir solução ótima global. Neste contexto, visando obter uma solução robusta para o problema, é proposto um procedimento de identificação ilustrado pela Figura 3.1, o qual é organizado em três etapas: (1) Identificação com modelos lineares, de forma a obter uma estimativa inicial dos parâmetros do modelo dinâmico; (2) Usando apenas dados de estado estacionário, determinam-se os parâmetros do modelo não linear que descreve o estado estacionário; (3) Determinam-se os parâmetros do modelo linear dinâmico, ver apêndice B, acoplado com o modelo não linear obtido na etapa (2), utilizando como estimativa inicial para os parâmetros do modelo dinâmico, os valores obtidos na etapa (1), em que ambos os modelos, estático e dinâmico são considerados lineares.

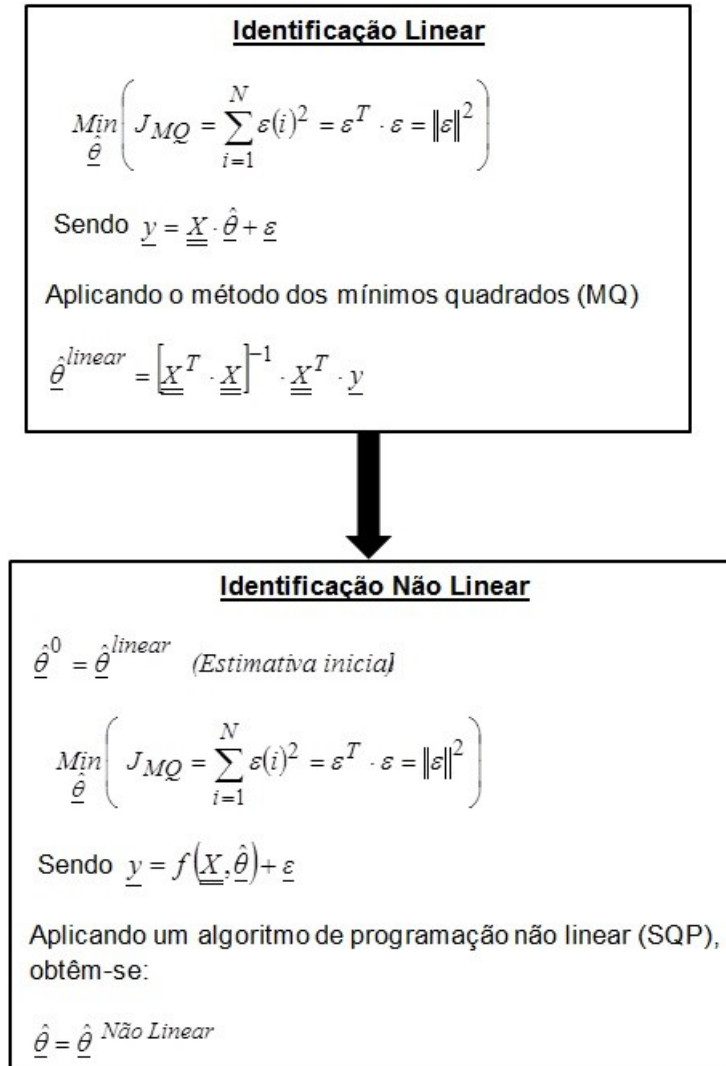


Figura 3.1: Metodologia de identificação não-linear proposta.

3.3 Integração do NMPC com a camada de otimização

Um dos desafios da otimização em tempo real é a integração efetiva com a camada de controle, porque em geral os modelos são diferentes. A camada de otimização utiliza modelos fenomenológicos, enquanto a camada de controle utiliza modelos empíricos, mais simples, que permitem resolver o problema de controle em uma taxa de frequência aceitável para controle. A diferença entre os modelos pode ocasionar em alvos irrealizáveis pela camada de controle. Nesse contexto, alguns autores têm proposto uma camada de otimização intermediária, no qual novos alvos são calculados com a parte estática dos modelos empíricos utilizados pelo controlador (ZANIN *et al.*, 2000). O problema de otimização da camada intermediária é formulado como uma função de minimização da soma dos quadrados da diferença entre os alvos da camada de otimização com modelos rigorosos e os alvos obtidos com a camada estática do modelo empírico do controlador. Desta forma, garante-se que os alvos enviados para a camada de controle são realizáveis, pois eles foram obtidos com o modelo estático do controlador. Porém, não existe garantia de que o ponto ótimo da camada intermediária seja o mesmo da camada de otimização com modelos fenomenológicos, resultando com isso em pontos subótimos realizáveis.

Na abordagem proposta, a parte estática do modelo não linear do controlador consegue descrever toda a região de otimização construída com os modelos rigorosos do processo, evitando a necessidade da camada intermediária de integração entre as camadas de otimização e de controle. A formulação matemática da camada de otimização é descrita nas Equações 3.12 a 3.15.

$$\{\mathbf{y}^A, \mathbf{u}^A\} = \arg \min_{\mathbf{y}(t_n), \mathbf{u}(t_n)} \phi(t_n) \quad (3.12)$$

Sujeito a restrições :

$$\mathbf{y}(t_n) = \mathbf{y}^{ss}(\mathbf{u}(t_n), \mathbf{d}(t_n)) \quad (3.13)$$

$$\mathbf{y}^L \leq \mathbf{y}(t_n) \leq \mathbf{y}^U \quad (3.14)$$

$$\mathbf{u}^L \leq \mathbf{u}(t_n) \leq \mathbf{u}^U \quad (3.15)$$

Sendo $\phi(t_n)$ a função objetivo no instante final t_n , $\mathbf{y}^{ss}(\mathbf{u}(t_n), \mathbf{d}(t_n)) \in \mathfrak{R}^{n_y}$ o modelo multi-paramétrico para descrever o estado-estacionário, $\mathbf{d}(t_n) \in \mathfrak{R}^{n_d}$ as variáveis de perturbação, $\mathbf{y}(t_n) \in \mathfrak{R}^{n_y}$ as variáveis controladas e $\mathbf{u}(t_n) \in \mathfrak{R}^{n_u}$ as variáveis manipu-

ladas. A solução ótima do problema de otimização consiste em $\mathbf{y}^A \in \mathfrak{R}^{n_y}$ e $\mathbf{u}^A \in \mathfrak{R}^{n_u}$.

Equações 3.16 a 3.20 mostram a camada de otimização rigorosa usando modelos fenomenológicos para representar o processo. A formulação é similar ao problema apresentado acima, mas substituindo o modelo proposto pelo modelo rigoroso, Equação 3.13.

$$\{\mathbf{y}^R, \mathbf{u}^R\} = \arg \min_{\mathbf{y}(t_n), \mathbf{u}(t_n)} \phi(t_n) \quad (3.16)$$

$$\mathbf{F}(\mathbf{x}(t_n), \mathbf{y}(t_n), \mathbf{u}(t_n), \mathbf{d}(t_n), t_n) = 0 \quad (3.17)$$

$$\dot{\mathbf{F}} = \mathbf{0} \quad (3.18)$$

$$\mathbf{y}^L \leq \mathbf{y}(t_n) \leq \mathbf{y}^U \quad (3.19)$$

$$\mathbf{u}^L \leq \mathbf{u}(t_n) \leq \mathbf{u}^U \quad (3.20)$$

Sendo $\phi(t_n)$ a função objetivo, $\mathbf{F}(\bullet) \in \mathfrak{R}^{n_x+n_y}$ é o sistema de equações algébricas, $\mathbf{x}(t_n) \in \mathfrak{R}^{n_x}$ são as variáveis de estado, $\mathbf{d}(t_n) \in \mathfrak{R}^{n_d}$ são as variáveis de perturbação, $\mathbf{y}(t_n) \in \mathfrak{R}^{n_y}$ são as variáveis controladas e $\mathbf{u}(t_n) \in \mathfrak{R}^{n_u}$ são as variáveis manipuladas. A solução ótima do problema de otimização usando o modelo rigoroso é $\mathbf{y}^R \in \mathfrak{R}^{n_y}$ e $\mathbf{u}^R \in \mathfrak{R}^{n_u}$

Equações 3.21 até 3.24 mostram a camada de otimização intermediária, necessária quando o modelo rigoroso for usado na camada de otimização e o modelo empírico for usado na camada de controle.

$$\{\mathbf{y}^I, \mathbf{u}^I\} = \arg \min_{\mathbf{y}(t_n), \mathbf{u}(t_n)} (\mathbf{y}(t_n) - \mathbf{y}^R(t_n))^2 \quad (3.21)$$

Sujeito as restrições :

$$\mathbf{y}(t_n) = \mathbf{y}^{ss}(\mathbf{u}(t_n), \mathbf{d}(t_n)) \quad (3.22)$$

$$\mathbf{u}_{min} \leq \mathbf{u}(t_n) \leq \mathbf{u}_{max} \quad (3.23)$$

$$\mathbf{y}_{min} \leq \mathbf{y}(t_n) \leq \mathbf{y}_{max} \quad (3.24)$$

Sendo $\mathbf{y}^{ss}(\mathbf{u}(t_n), \mathbf{d}(t_n)) \in \mathfrak{R}^{n_y}$ o modelo multi-paramétrico para descrever o estado estacionário, $\mathbf{d}(t_n) \in \mathfrak{R}^{n_d}$ são as variáveis de perturbação, $\mathbf{y}(t_n) \in \mathfrak{R}^{n_y}$ são as variáveis controladas e $\mathbf{u}(t_n) \in \mathfrak{R}^{n_u}$ são as variáveis manipuladas. A solução ótima da camada

de otimização intermediária é $\mathbf{y}^I \in \mathfrak{R}^{n_y}$ e $\mathbf{u}^I \in \mathfrak{R}^{n_u}$.

A equação 3.25 é empregada na integração entre as camadas de controle e otimização quando existe uma camada de otimização intermediária. Por outro lado, a integração com a abordagem proposta é representada pela Equação 3.26 com $\mathbf{y}^A(t_n)$ enviados diretamente para a camada de controle.

$$\mathbf{y}^{SP}(t_k) = \mathbf{y}^I(t_n), \quad t_k \in [t_0, t_n] \quad (3.25)$$

$$\mathbf{y}^{SP}(t_k) = \mathbf{y}^A(t_n) \cong \mathbf{y}^R(t_n), \quad t_k \in [t_0, t_n] \quad (3.26)$$

O desempenho de técnicas de otimização em tempo real baseada em modelos estáticos depende de quão próximo o processo esteja do regime estacionário, condição operacional incomum em plantas industriais. Neste caso, a camada de controle conduziria a planta para um alvo subótimo, definido pela camada de otimização baseada em modelos estáticos (JASCHKE *et al.*, 2014).

Neste contexto, a otimização dinâmica em tempo real (DRTO), no qual o comportamento dinâmico do processo é descrito por um conjunto de equações algébrico-diferenciais, surge como alternativa mais adequada. O maior desafio dessa técnica é evitar os “*infeasible path*”, ou seja, regiões de inviabilidade física do processo que podem ocorrer durante a solução do problema de otimização. Essas regiões de inviabilidade ocorrem quando as condições iniciais das variáveis de estado em conjunto com a direção de suas derivadas conduzem o processo para uma condição de violação das restrições. Além disso, outros fatores podem levar à violação dessas restrições, são eles: erros de modelagem, perturbações abruptas, mudança de especificação de produtos que podem acarretar alteração das restrições do problema.

Técnicas utilizadas para tratar restrições de problemas de otimização linear e de otimização não linear são ineficientes para resolver alguns problemas de inviabilidade presentes em condições iniciais ou em pontos intermediários da solução de problemas de otimização algébrico-diferenciais (DAOP). Visando contornar esse tipo de problema, ALMEIDA e SECCHI (2012) propuseram uma abordagem para resolver o problema de otimização, através de uma formulação multiobjetivo, da inclusão da variável tempo como grau de liberdade e de técnicas de relaxamento das restrições. Os resultados apresentados no trabalho demonstraram o sucesso da técnica em fornecer mais robustez aos sistemas de DRTO.

Neste trabalho, o NMPC proposto foi integrado com uma camada de otimização dinâmica, baseada em modelos fenomenológicos do processo, sem a necessidade de uma camada intermediária para integrar as duas estratégias de controle e oti-

mização. A formulação matemática da camada de otimização dinâmica é descrita nas Equações 3.27 a 3.28.

$$\{\mathbf{y}^{DR}(t_k), \mathbf{u}^{DR}(t_k)\} = \arg \min_{\mathbf{y}(t_k), \mathbf{u}(t_k)} \phi(t_n) \quad (3.27)$$

Sujeito a:

$$\begin{aligned} \mathbf{F}(\dot{\mathbf{x}}(t_k), \mathbf{x}(t_k), \mathbf{y}(t_k), \mathbf{u}(t_k), t_k) &= \mathbf{0}, \quad x(t_0) = x_0; \quad t_k \in [t_0, t_n] \\ \mathbf{x}^L &\leq \mathbf{x}(t_k) \leq \mathbf{x}^U \\ \mathbf{y}^L &\leq \mathbf{y}(t_k) \leq \mathbf{y}^U \\ \mathbf{u}^L &\leq \mathbf{u}(t_k) \leq \mathbf{u}^U \end{aligned} \quad (3.28)$$

Sendo $\phi(t_n)$ a função objetivo, $F(\bullet) \in \mathfrak{R}^{n_x+n_y}$ o sistema de equações algébrico-diferenciais (DAE), $\mathbf{x}(t_k) \in \mathfrak{R}^{n_x}$ são as variáveis de estado, $\mathbf{y}(t_k) \in \mathfrak{R}^{n_y}$ são as variáveis controladas, $\mathbf{u}(t_k) \in \mathfrak{R}^{n_u}$ são as variáveis manipuladas.

O problema de otimização algébrica-diferencial (DAOP) descrito pelas Equações 3.27 e 3.28 foi reformulado como um problema de otimização multi-objetivo usando técnicas de relaxação das restrições variantes no tempo. As Equações 3.29 e 3.30 mostram a formulação matemática do problema de otimização multi-objetivo pela relaxação das restrições utilizando variáveis de folga variantes no tempo, $s(t)$, (ALMEIDA e SECCHI, 2012).

$$\min_{\mathbf{u}(t_k), \mathbf{s}^x(t_k), \mathbf{s}^y(t_k), \mathbf{s}^u(t_k)} \left[\phi(t_n), \int_0^{t_f} (\mathbf{s}^x(t))^2 dt, \int_0^{t_f} (\mathbf{s}^y(t))^2 dt, \int_0^{t_f} (\mathbf{s}^u(t))^2 dt, \right] \quad (3.29)$$

Sujeito a restrições:

$$\begin{aligned} F(\dot{\mathbf{x}}(t_k), \mathbf{x}(t_k), \mathbf{y}(t_k), \mathbf{u}(t_k), t_k) &= \mathbf{0}, \quad x(t_0) = x_0; \quad t_k \in [t_0, t_n] \\ \mathbf{x}^L &\leq \mathbf{x}(t_k) + \mathbf{s}^x(t_k) \leq \mathbf{x}^U \\ \mathbf{y}^L &\leq \mathbf{y}(t_k) + \mathbf{s}^y(t_k) \leq \mathbf{y}^U \\ \mathbf{u}^L &\leq \mathbf{u}(t_k) + \mathbf{s}^u(t_k) \leq \mathbf{u}^U \\ \mathbf{s}_L^x &\leq \mathbf{s}^x(t_k) \leq \mathbf{s}_U^x & \text{sendo} & \mathbf{s}^x(t_k) \in \mathfrak{R}^{n_x} \\ \mathbf{s}_L^y &\leq \mathbf{s}^y(t_k) \leq \mathbf{s}_U^y & \text{sendo} & \mathbf{s}^y(t_k) \in \mathfrak{R}^{n_y} \\ \mathbf{s}_L^u &\leq \mathbf{s}^u(t_k) \leq \mathbf{s}_U^u & \text{sendo} & \mathbf{s}^u(t_k) \in \mathfrak{R}^{n_u} \end{aligned} \quad (3.30)$$

Sendo $\mathbf{s}^x(t_k)$ as variáveis de folga de relaxação das restrições para as variáveis de es-

tado, $\mathbf{s}^y(t_k)$ são as variáveis de folga de relaxação das restrições para as variáveis controladas e $\mathbf{s}^u(t_k)$ são as variáveis slacks de relaxação das restrições para as variáveis manipuladas.

A abordagem proposta permite a integração direta entre a camada de otimização dinâmica e a camada de controle, Equação 3.31.

$$\mathbf{y}^{SP}(t_k) = \mathbf{y}^{DR}(t_k), \quad t_k \in [t_0, t_n] \quad (3.31)$$

No capítulo seguinte será mostrado que o modelo proposto consegue descrever a trajetória de otimização sugerida pela camada de D-RTO, com a vantagem de redução do custo computacional. Este fato permite incluir na função objetivo do controlador uma parcela relativa ao balanço econômico do processo, evitando com isso, a necessidade de haver uma camada segregada realizando otimização. A grande vantagem disso é conseguir resolver o problema de otimização econômica na mesma frequência do problema de controle, transformando-o em uma estratégia de controle preditivo não linear econômico (ENMPC).

Capítulo 4

Resultados e discussões

4.1 Caso 0 - Aplicação do NMPC proposto em um reator CSTR não-isotérmico

Um problema *benchmark* da literatura, reator CSTR (*controlled stirred tank reactor*) de Van de Vusse (DE VUSSE, 1964), foi escolhido como estudo de caso devido ao seu comportamento não linear bem-conhecido. O sistema é representado pela síntese do ciclopentenol (componente B) através do ciclopentadieno (componente A) com adição de água-ácida como catalisador. A forte reatividade entre reagentes e produtos na reação de Diels-Alder ocasiona a produção de subprodutos, díciclopentadieno (component D) e ciclopentanodiol (componente C) quando é adicionada uma molécula adicional de H_2O (KLATT e ENGELL, 1998).





Figura 4.1: Esquema do reator de Van De Vusse.



As Equações 4.1 a 4.4 a seguir descrevem os balanços de massa e energia no reator CSTR, considerando volume constante no reator.

$$\frac{dC_a}{dt} = \frac{F}{V} (C_{a_{in}} - C_a) - K_1(T) C_a - K_3(T) C_a^2 \quad (4.1)$$

$$\frac{dC_b}{dt} = -\frac{F}{V} C_b + K_1(T) C_a - K_2(T) C_b \quad (4.2)$$

$$\begin{aligned} \frac{dT}{dt} = & -\frac{1}{\rho C_p} [K_1(T) C_a (-\Delta H_{RAB}) + K_2(T) C_b (-\Delta H_{RBC}) \\ & + K_3(T) C_a^2 (-\Delta H_{RAD})] + \frac{F}{V} (T_{in} - T) + \frac{K_w A_R}{\rho C_p V} (T_w - T) \end{aligned} \quad (4.3)$$

$$K_i(T) = K_{i0} \exp\left(-\frac{E_i}{RT}\right) \quad (4.4)$$

Sendo C_a e C_b as concentrações molares dos componentes A e B, respectivamente, $C_{a_{in}}$ é a concentração molar do componente A na entrada do reator, T é a temperatura do reator, T_w é a temperatura do fluido de resfriamento na jaqueta, T_{in} é a temperatura do fluido de alimentação do reator, F é a vazão de alimentação, V é o volume do reator, A_R é a área de troca térmica, K_w é o coeficiente de troca térmica na parede do reator. A Tabela 4.1 mostra os valores dos parâmetros do modelo.

A Figura 4.2 ilustra o comportamento não linear do estado-estacionário da composição do componente C_b como função das variáveis manipuladas, F e T_w , do reator de Van De Vusse. Esse estudo de caso é adequado para verificar a performance do controlador, pois existe não-linearidade da principal variável controlada C_b com as variáveis manipuladas, F e T_w . A análise das curvas na figura, considerando T_w constante, comprova a existência de inversão de ganho na relação entre a composição do componente C_b com a vazão de alimentação. Por outro lado, se subirmos a T_w para patamares mais altos, mantendo a vazão de alimentação constante e próxima do limite de mínimo, é possível notar que a taxa de reação diminuirá e por consequência a produção do componente C_b também. Entretanto, no outro extremo da vazão de alimentação, próximo ao limite superior e considerando-a constante, ocorre o comportamento oposto, ou seja, conforme a T_w aumenta, a taxa de reação aumentará e com isso a produção de C_b . Este fato comprova a presença de inversão de ganho também na relação entre as variáveis de T_w e C_b . Outro resultado interessante desta figura é mostrar que o modelo multi-paramétrico proposto consegue descrever bem o comportamento não linear da planta.




Figura 4.2: Composição do estado estacionário de C_b .

Tabela 4.1: Parâmetros do estudo de caso do CSTR (DE VUSSE, 1964)

Parâmetros do Reator	Valor	Unidade
K_{10}	$1,287 \times 10^{12}$	h^{-1}
K_{20}	$1,287 \times 10^{12}$	h^{-1}
K_{30}	$9,043 \times 10^9$	$L/(molA.h)$
$(-E_1/R)$	9758,3	K
$(-E_2/R)$	9758,3	K
$(-E_3/R)$	8560,0	K
$(-\Delta H_{RAB})$	-4,20	$kJ/mol A$
$(-\Delta H_{RBC})$	11,00	$kJ/mol B$
$(-\Delta H_{RAD})$	41,85	$kJ/mol A$
ρ	0,9342	kg/L
C_p	3,01	$kJ/(kgK)$
K_w	4032,0	$kJ/(hKm^2)$
A_R	0,215	m^2
V	10	L

4.1.1 Identificação do Processo

O NMPC foi configurado com duas variáveis manipuladas, F e T_w , duas variáveis controladas, C_b e T , e duas variáveis perturbações, Ca_{in} e T_{in} . As Equações 3.6 a 3.9 são representações das Equações 4.5 a 4.8 usadas para descrever o comportamento do reator de Van de Vusse no algoritmo MPC. As Tabelas 4.2 e 4.3 mostram os parâmetros obtidos na etapa de identificação.

Tabela 4.2: Parâmetros do modelo de estado-estacionário

$C_{j,l}$	$k_{j,l,1}$	$k_{j,l,2}$	$k_{j,l,3}$	$k_{j,l,4}$	$k_{j,l,5}$	$k_{j,l,6}$
$C_{1,1}$	0,3236	0,1525	0,3805	-0,049	0,0028	-0,359
$C_{1,2}$	-1,077	-0,599	-0,182	2,9490	0,1381	7,8941
$C_{1,3}$	0,5271	0,4653	1,6030	5,7304	0,3474	10,922
$C_{1,4}$	2,5515	1,0075	-1,599	-11,35	-0,654	-22,91
$C_{1,5}$	0,7214	0,590	1,0970	-4,665	-0,143	-12,54
$C_{1,6}$	1,9308	0,977	-1,185	-15,01	-0,885	-36,81
$C_{2,1}$	90,595	1,509	33,818	1,6809	0,4415	2,4816
$C_{2,2}$	18,698	-2,42	37,410	15,276	0,3364	11,631
$C_{2,3}$	77,542	4,388	6,6873	24,790	2,8896	4,6919
$C_{2,4}$	-116,3	5,245	-6,556	-36,78	-0,991	9,9687
$C_{2,5}$	-6,956	-0,70	-54,04	-22,61	-1,303	-11,32
$C_{2,6}$	4,6948	5,214	-4,864	-68,70	-3,957	-62,69

$$y_j(t) = y_j^0 + [y_j^0 - y_j^{ss}(F, T_w, C_{a_{in}}, T_{in})] f_j(t) \quad (4.5)$$

$$f_j(t) = 1 - \exp\left(\frac{-\varepsilon_j(t - \tau_{d_j})}{\tau_j}\right) \left\{ \cosh\left[\frac{\sqrt{\varepsilon_j^2 - 1}}{\tau_j}(t - \tau_{d_j})\right] + \frac{\varepsilon_j}{\sqrt{\varepsilon_j^2 - 1}} \sinh\left[\frac{\sqrt{\varepsilon_j^2 - 1}}{\tau_j}(t - \tau_{d_j})\right] \right\} \quad (4.6)$$

$$y_j^{ss} = [C_b^{ss}, T^{ss}] \quad e \quad y_j(t) = [C_b(t), T(t)]$$

$$y_j^{ss}(F, T_w, C_{a_{in}}, T_{in}) = C_{j,1} + C_{j,2}(C_{a_{in}}, T_{in}) F + C_{j,3}(C_{a_{in}}, T_{in}) T_w + C_{j,4}(C_{a_{in}}, T_{in}) F T_w + C_{j,5}(C_{a_{in}}, T_{in}) F^2 + C_{j,6}(C_{a_{in}}, T_{in}) T_w^2 \quad (4.7)$$

$$C_{j,l}(C_{a_{in}}, T_{in}) = k_{j,l,1} + k_{j,l,2} C_{a_{in}} + k_{j,l,3} T_{in} + k_{j,l,4} C_{a_{in}} T_{in} + k_{j,l,5} C_{a_{in}}^2 + k_{j,l,6} T_{in}^2 \quad (4.8)$$

Tabela 4.3: Parâmetros do modelo dinâmico

Parâmetros	ε_j	τ_j	τ_{d_j}
$f_1(t)$	1.887	0.1905	0.00234
$f_2(t)$	2.903	0.8050	1.1×10^{-5}

As Figuras 4.3 a 4.6 ilustram uma comparação entre os comportamentos da planta e do modelo proposto para as controladas, C_b e T , quando aplicados degraus nas manipuladas, vazão de alimentação e temperatura do fluido resfriamento, F e T_w e nas perturbações, concentração de alimentação do componente A e temperatura de alimentação, $C_{a_{in}}$ e T_{in} . Os resultados mostram que os modelos propostos para $C_b(t)$ e $T(t)$ descrevem bem o comportamento da planta em todas as regiões, apesar de o modelo para descrever $C_b(t)$ apresentar erro médio relativo de 2.5% ilustrado na Figura 4.3, em que Cb_p é o valor da planta e Cb_m é o valor do modelo. Sendo assim, é possível concluir que os modelos propostos são adequados para estratégias de controle e otimização.

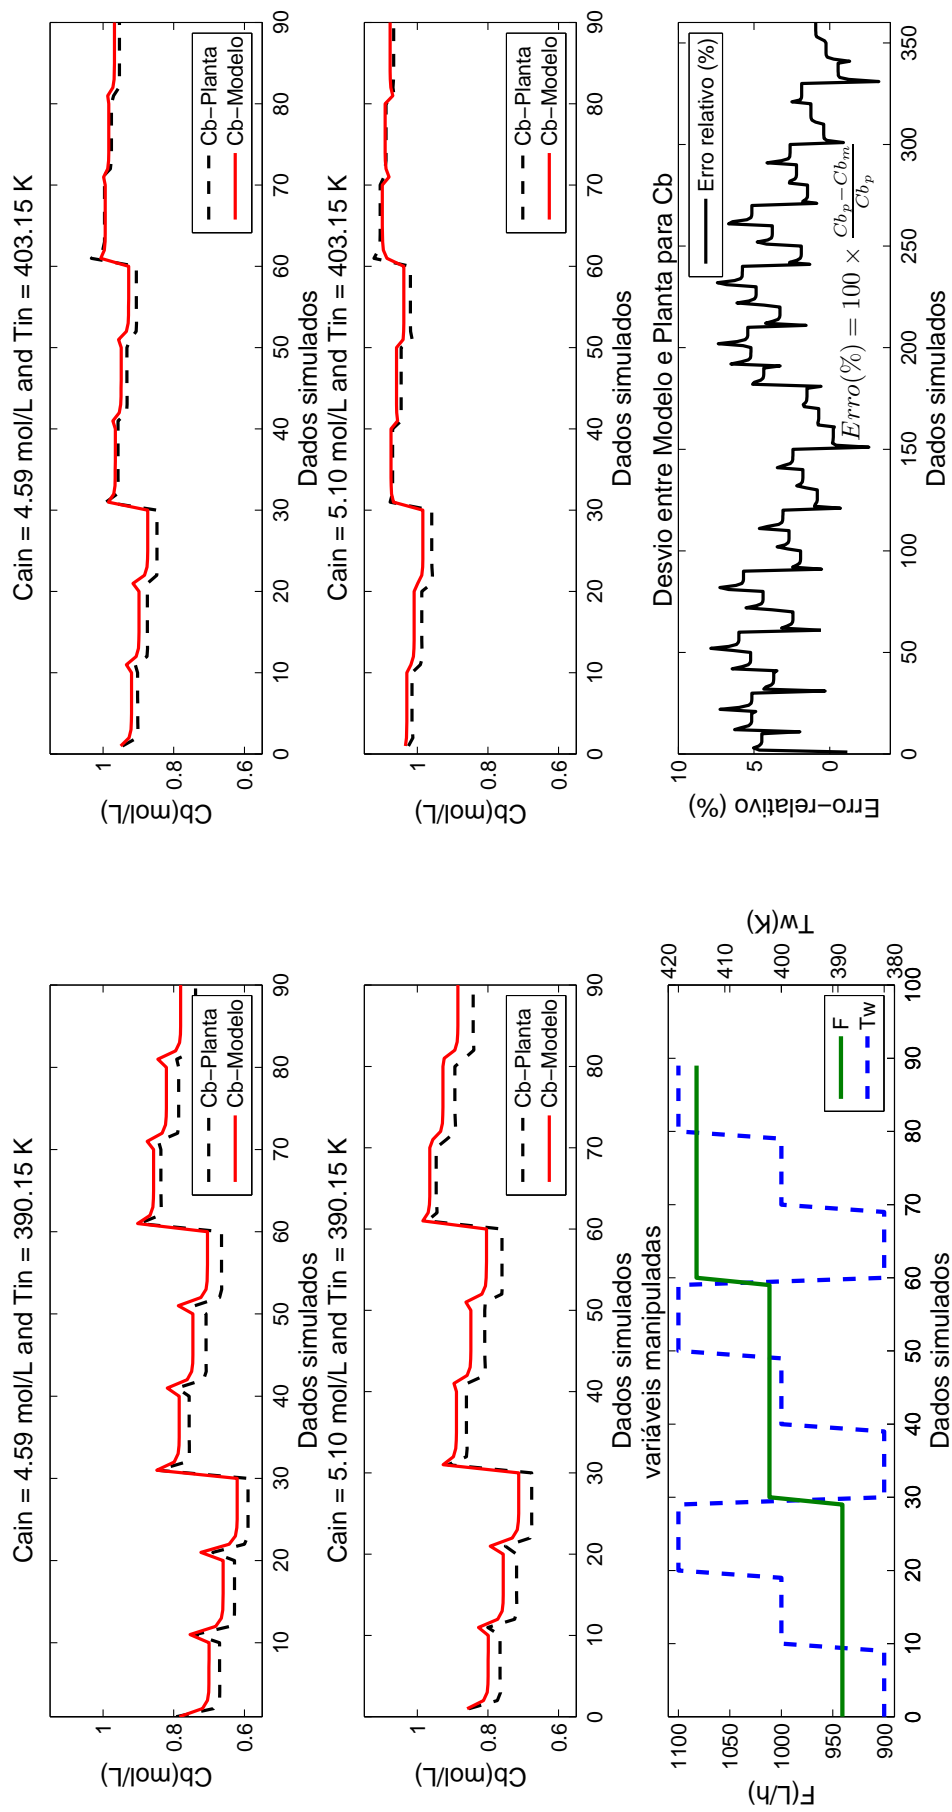


Figura 4.3: identificação do modelo dinâmico da concentração do componente B, C_b




Figura 4.4: Identificação do modelo dinâmico da Temperatura de reação

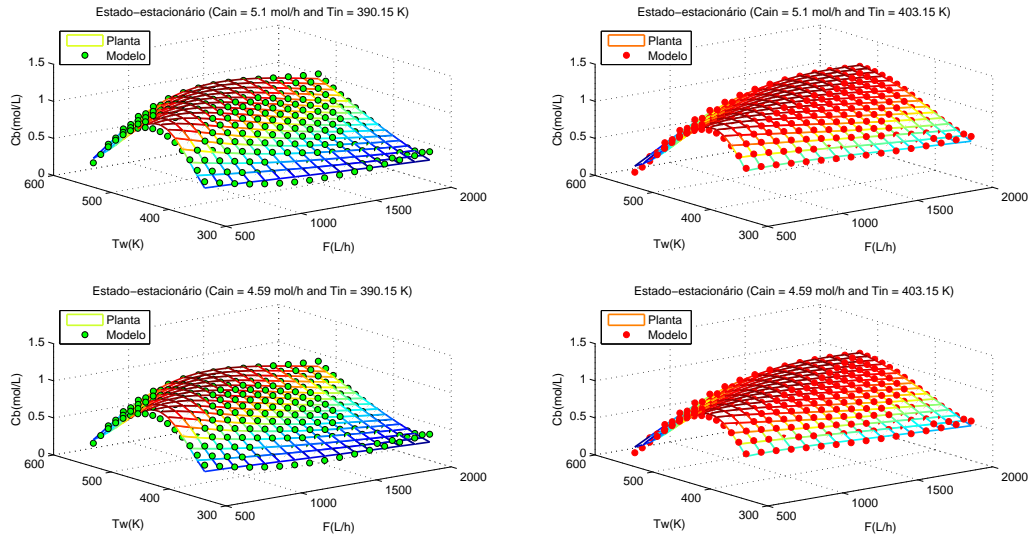


Figura 4.5: Identificação do modelo de estado-estacionário da concentração do componente B, C_b

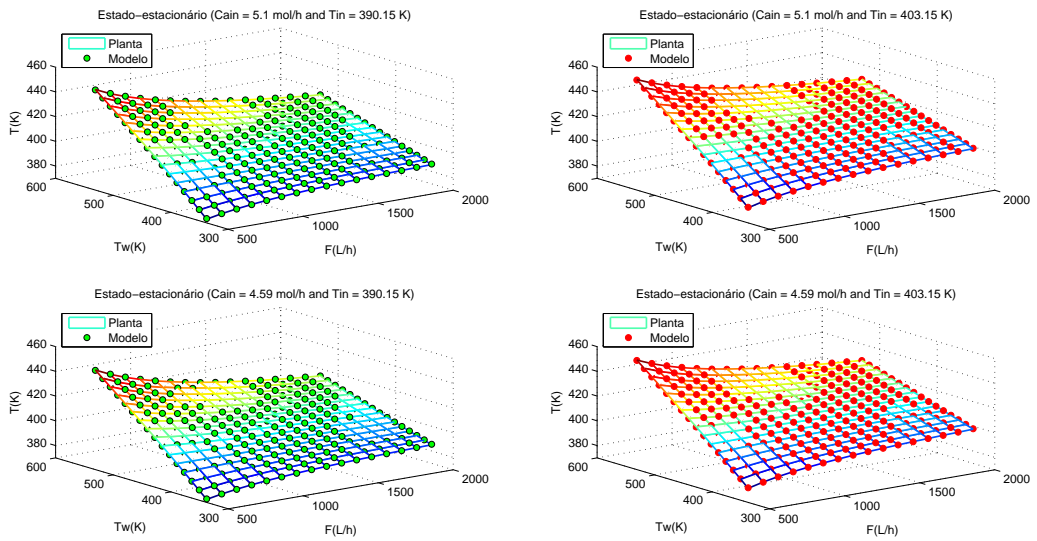


Figura 4.6: Identificação do modelo de estado-estacionário para a Temperatura.

4.1.2 Aplicação do NMPC proposto no estudo de caso do CSTR

A formulação da estratégia NMPC proposta é descrita na Equação 3.1 da seguinte forma : $y^{SP}(t_k) = [C_b^{SP}(t_k), T^{SP}(t_k)]$, $y(t_k) = [C_b(t_k), T(t_k)]$ e $u(t_k) = [F(t_k), T_w(t_k)]$, sendo a máxima variação das manipuladas: $\Delta u(t_k) = [\Delta F(t_k), \Delta T_w(t_k)] = [100L/h, 10K]$, $W(t_k) = [W_{C_b}(t_k), W_T(t_k)] = [100, 10]$, $S(t_k) = [R_{\Delta F}(t_k), R_{\Delta T_w}(t_k)] = [10, 10]$, $R(t_k) = [R_F(t_k), R_{T_w}(t_k)] = [1, 1]$, $t_{amostragem} = 5min$, $H_P = 50$, $H_C = 10$. O objetivo desse estudo foi comparar o desempenho do NMPC proposto em conduzir, de forma suave, a planta para os objetivos propostos de C_b e T em dois cenários: (1) Utilizando o modelo não linear proposto e (2) Utilizando o modelo perfeito da planta, descrito pelas equações fenomenológicas que regem o processo. Além disso, essa comparação foi realizada também para um problema regulatório, em que o objetivo do controlador é rejeitar perturbações na composição dos componentes de alimentação e da temperatura da vazão de alimentação.

As Figuras 4.7 a 4.8 ilustram o bom desempenho do NMPC proposto em conduzir a planta suavemente para os alvos sugeridos. Os gráficos mostram um pequeno desvio na temperatura no período de tempo anterior ao degrau no objetivo de produção do componente B, C_b . Este fato pode ser explicado pela perda de grau de liberdade da vazão de alimentação que alcança o limite mínimo permitido a ela no problema de controle, deixando o controlador com apenas um grau de liberdade para controlar dois objetivos. Sendo que, os parâmetros de sintonia do controlador foram escolhidos de forma a priorizar alcançar o objetivo proposto para a produção do componente B, C_b em detrimento ao atingimento do objetivo proposto para a temperatura de reação. O código foi desenvolvido no ambiente de programação MatLab e o algoritmo de otimização selecionado para resolver o problema não linear de controle foi o de ponto interior, (BYRD *et al.*, 1999). O algoritmo não apresentou custo computacional muito elevado, aproximadamente 0,66 segundos por ciclo de controle, em uma máquina com 8GB de memória RAM e processador i7, para resolver o problema NLP com duas variáveis manipuladas, duas variáveis controladas e duas variáveis de perturbação.

As Figuras 4.9 e 4.10 mostram bom desempenho do controlador proposto em rejeitar perturbações na alimentação, $C_{a_{in}}$ e T_{in} , mantendo as variáveis controladas, C_b e T , nos alvos. Similar a resultados anteriores, existe um *offset* para a variável controlada temperatura causada pela perda de um dos graus de liberdade do NMPC, quando a vazão de alimentação alcança o limite mínimo, deixando o controlador com apenas uma variável manipulada para controlar duas variáveis controladas.

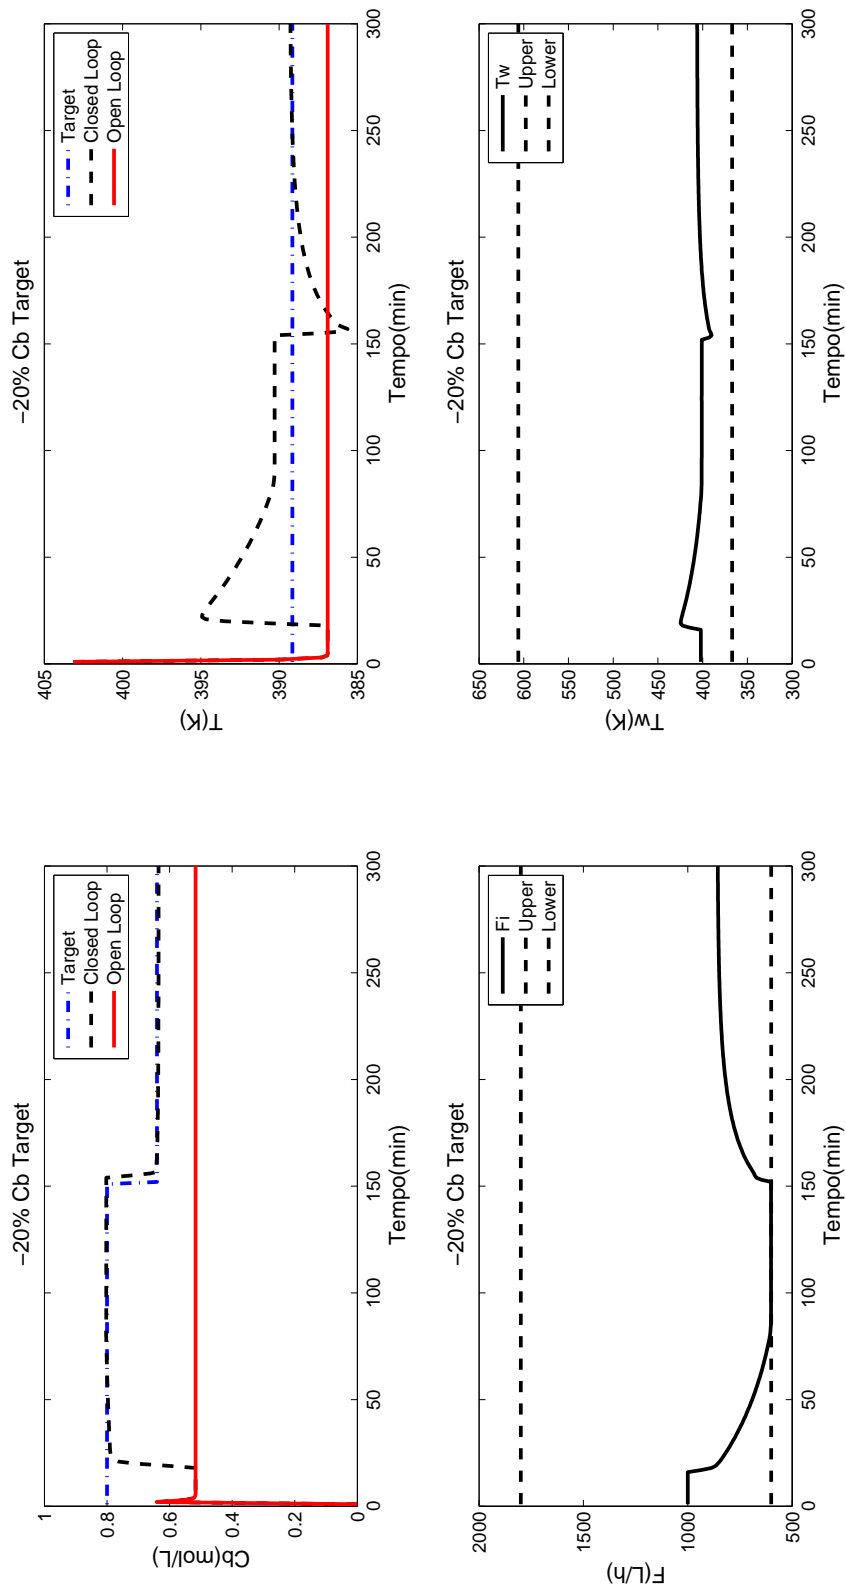


Figura 4.7: Resultado do NMPC proposto para conduzir a planta até os alvos sugeridos para as variáveis controladas C_b e T , sendo a malha de controle fechada no instante de tempo 15 min e a alteração no alvo de C_b realizada no instante de tempo 150 min

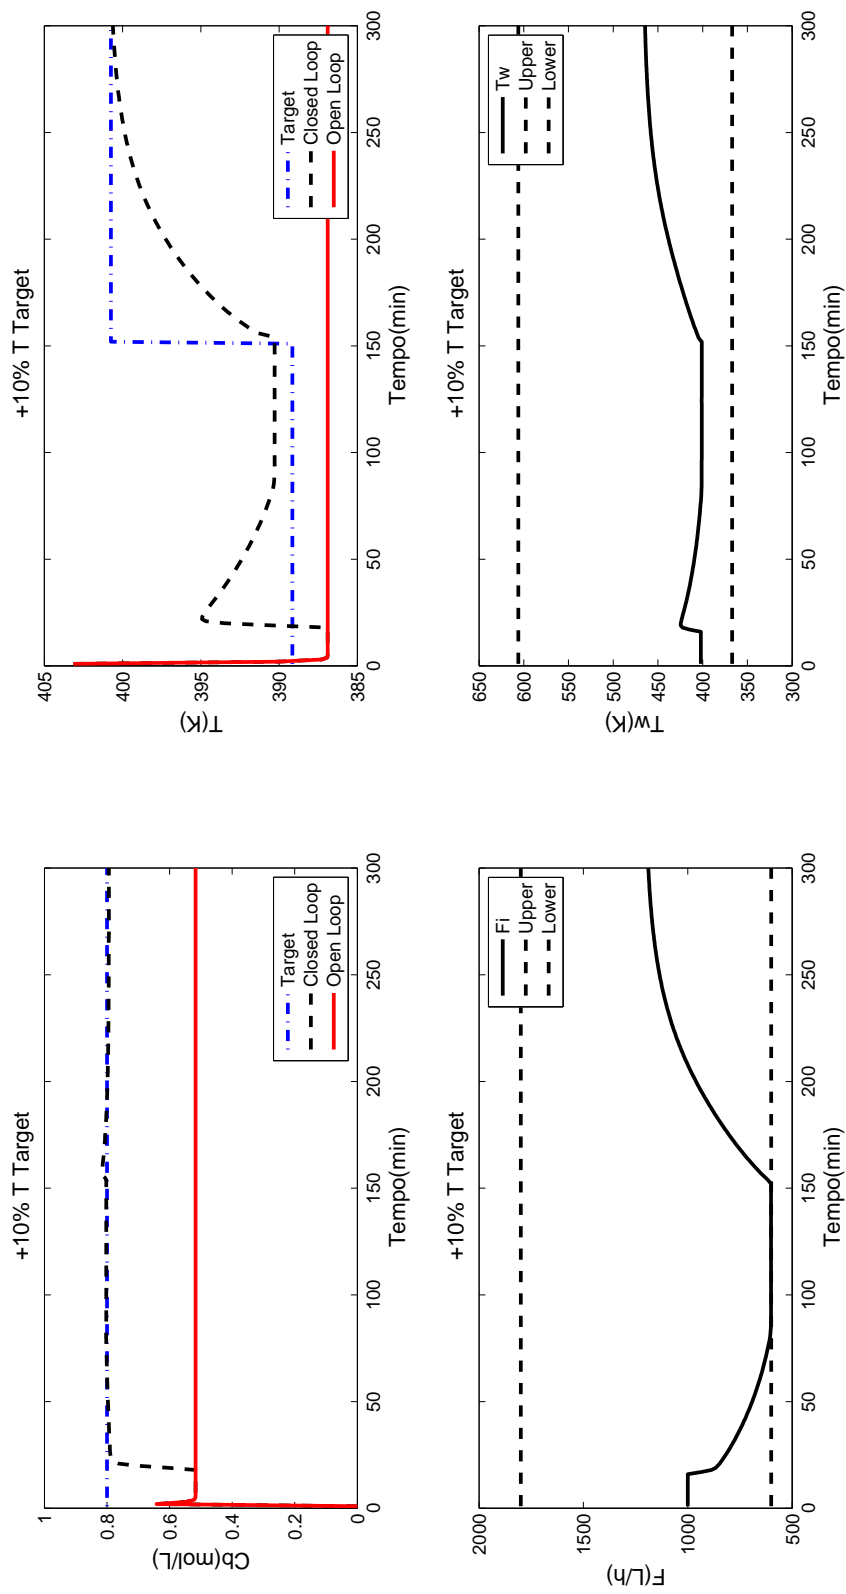


Figura 4.8: Resultado do NMPC proposto para conduzir a planta até os alvos sugeridos para as variáveis controladas C_b e T , sendo a malha de controle fechada no instante de tempo 15 min e a alteração no alvo de T realizada no instante de tempo 150 min

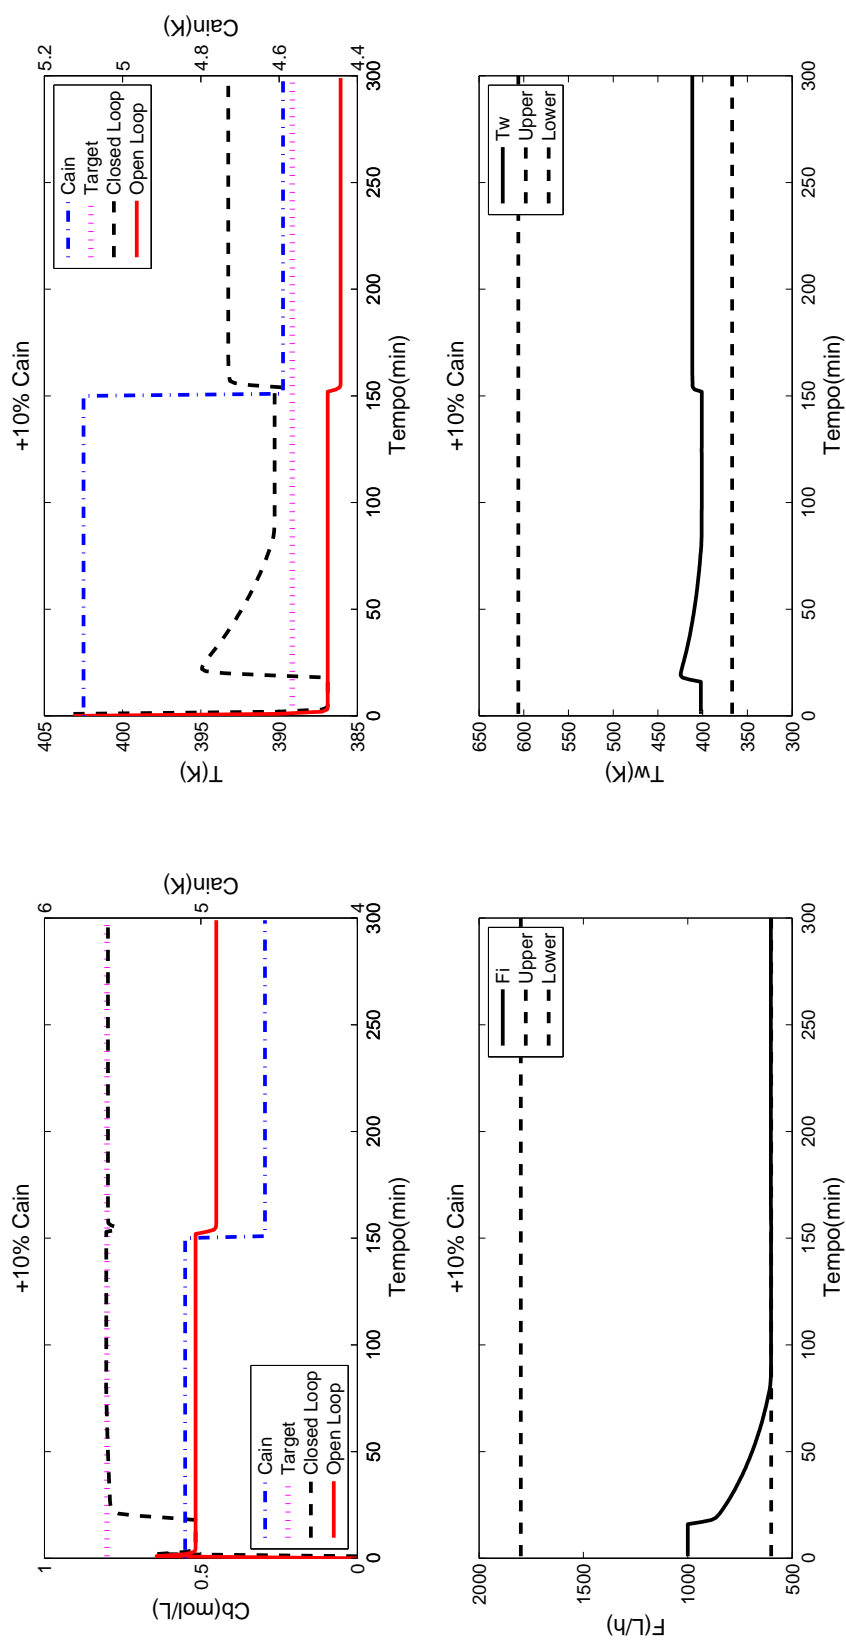


Figura 4.9: Resultado do NMPC proposto para rejeitar perturbações na composição da vazão de alimentação, sendo a malha fechada no instante de tempo 15 min e com a perturbação aplicada no instante de tempo 150 min




Figura 4.10: Resultado do NMPC proposto para rejeitar perturbações na temperatura da vazão de alimentação, sendo a malha fechada no instante de tempo 15 min e com a perturbação aplicada no instante de tempo 150 min

As Figuras 4.11 e 4.12 mostram os desempenhos do NMPC proposto e do QDMC (GARCIA e MORSHEDI, 1986) usando o modelo linear obtido na primeira etapa do procedimento de identificação. Os resultados com o NMPC proposto mostram *offsets* nas variáveis controladas para alguns patamarers de *targets*. No primeiro par de alvos onde o NMPC deixa *offset*, é verificado que ambas as variáveis manipuladas atingem os limites mínimos. Na segunda região de *offset*, observa-se *offset* apenas na concentração de C_b , isso ocorre porque a solução do problema de controle conduz a temperatura da jaqueta para o limite máximo, deixando o controlador com apenas um grau de liberdade para controlar duas variáveis controladas. Porém, em todas as situações o NMPC apresentou boa performance com os limites selecionados para as variáveis manipuladas. Por outro lado, os resultados obtidos com o algoritmo QDMC foram oscilatórios, mostrando a dificuldade do algoritmo em controlar um processo com comportamento não linear através de um modelo linear.

As Figuras 4.13 e 4.14 ilustram uma comparação entre o algoritmo NMPC usando o modelo rigoroso com o NMPC usando o modelo proposto. Existem *offsets* nas três regiões operacionais. Na primeira região, o *target* de C_b é irrealizável com os limites escolhidos para a variável manipulada F_i usada no problema de controle, como ilustrado na Figura 4.2. Na segunda região, quando os targets mudam novamente, existe *offset* apenas na composição de C_b . Isso aconteceu porque as soluções do problema de controle levaram a vazão de alimentação, F_i , para o limite mínimo, deixando o controlador com apenas uma variável manipulada para controlar duas variáveis. Na última região, ambas as variáveis manipuladas atingiram os limites mínimo, deixando *offset* para as duas variáveis controladas. Apesar dos offsets, é possível concluir que o NMPC apresentou um bom desempenho e que a perda de desempenho em algumas situações foi por conta do atingimento dos limites definidos para a região de busca do controlador. Sendo assim, os resultados comprovam que o uso do modelo não linear proposto não ocasiona perda significativa de performance quando comparado ao desempenho do controlador com o modelo rigoroso da planta. Entretanto, o NMPC proposto reduziu significativamente o tempo computacional para resolver o problema NLP. Em outras palavras, o tempo gasto em cada ciclo de controle do NMPC usando o modelo proposto reduziu em 15x o tempo computacional gasto com o algoritmo usando o modelo rigoroso. Este resultado é muito importante, mostrando o potencial da estratégia proposta para aplicação em problemas de larga-escala.




Figura 4.11: Comparação entre as variáveis controladas obtidas com o NMPC proposto e uma estratégia QDMC tradicional.

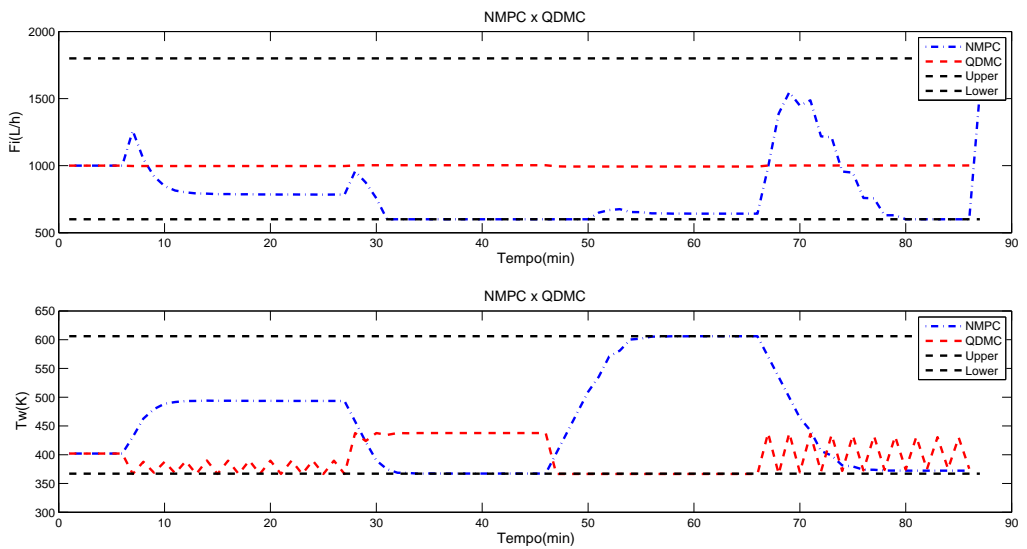


Figura 4.12: Comparação entre as variáveis manipuladas obtidas como solução do problema de controle do NMPC proposto com uma estratégia tradicional QDMC.

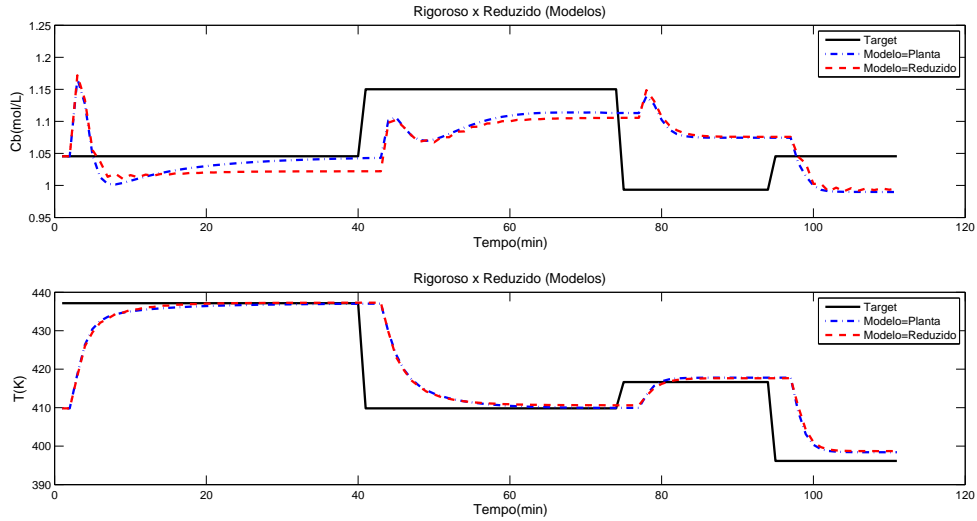


Figura 4.13: Comparação entre as variáveis controladas obtidas com o algoritmo NMPC usando o modelo proposto e com o algoritmo usando o modelo rigoroso.

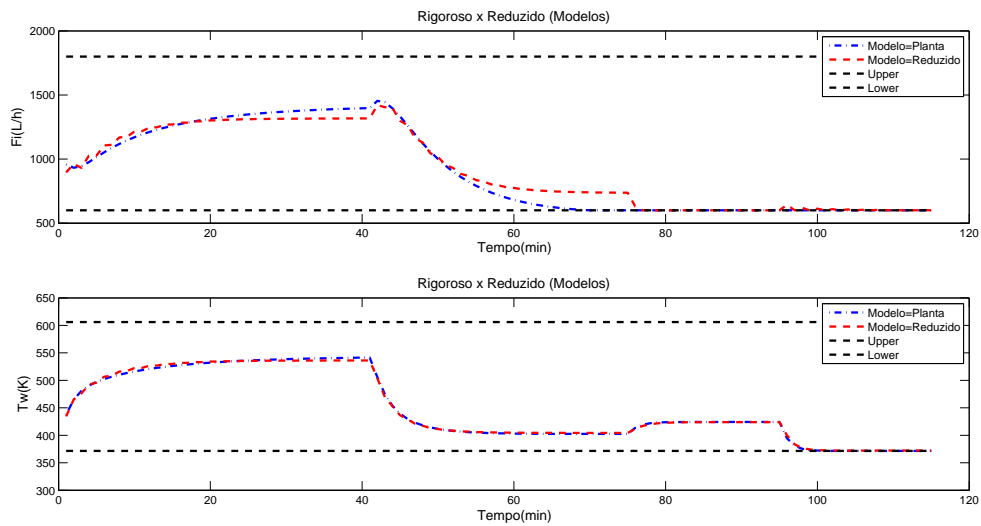


Figura 4.14: Comparação entre as variáveis manipuladas obtidas com o algoritmo NMPC usando o modelo proposto e com o algoritmo usando o modelo rigoroso.

4.1.3 Análise de sensibilidade aos erros de modelagem do modelo proposto para o NMPC

A Figura 4.15 mostra a predição de estado-estacionário obtida ao final de cada ciclo de controle para 3 estudos de caso: (1) Sem erro de modelagem - O modelo usado pelo NMPC proposto tem todos os parâmetros obtidos através da identificação do processo; (2) Erro aleatório de modelagem com variabilidade dentro da faixa de 5%; (3) Erro aleatório de modelagem com variabilidade dentro da faixa de 40%. Os resultados ilustram que existe baixo desempenho no cálculo da trajetória de predição apenas quando os erros estão nos parâmetros dos modelos que descrevem o estado-estacionário do processo e, principalmente, quando estes erros apresentam grande valor.

A Figura 4.16 mostra o desempenho do controlador para erros de modelagem em descrever o estado-estacionário do processo. O controlador não conseguiu conduzir a planta para os objetivos sugeridos para o caso em que o erro de modelagem apresenta variabilidade da ordem de 40%. Valores de erro nesse patamar não são esperados em condições operacionais da planta que sejam parecidas com a condição operacional em que os testes foram feitos para levantar os dados de processo utilizados na etapa de identificação. Portanto, pode-se dizer que em operações normais de operação o controlador com o modelo proposto apresenta robustez a erros de modelagem.

O baixo desempenho apresentado pelo controlador acontece porque o sistema perde a temperatura do fluido de resfriamento como grau de liberdade, T_w , atinge o limite de máximo, deixando o controlador com apenas uma variável manipulada para controlar duas variáveis controladas. Analisando os resultados, é possível concluir a importância de obter modelos acurados para descrever o comportamento não-linear do estado-estacionário.

As Figuras 4.17 e 4.18 mostram o desempenho do controlador frente a erros de modelagem dinâmica. Os estudos de caso são os mesmos descritos para os erros de modelagem do estado estacionário, porém com erros nos parâmetros τ_p e ϵ , respectivamente. Os resultados mostram um comportamento do controlador diferente dos casos em que os erros de modelagem estão concentrados em descrever o comportamento estático da planta, onde a performance do controlador é fortemente impactada para grandes variabilidades de erros. Nesses estudos de caso, o erro de modelagem para descrever a dinâmica do processo não impactou o desempenho do controlador, independente da ordem de grandeza da variabilidade do erro.




Figura 4.15: Resultado do NMPC proposto com erro de modelagem de estado estacionário, cujo objetivo é manter Cb e a temperatura no setpoint. O controlador entra em operação no instante $t=15\text{min}$ e uma perturbação é adicionada ao sistema em $t=150\text{min}$.




Figura 4.16: NMPC proposto com erros no modelo estático para o problema servo. A malha de controle é fechada em $t=15$ min e o setpoint muda em $t=150$ min.

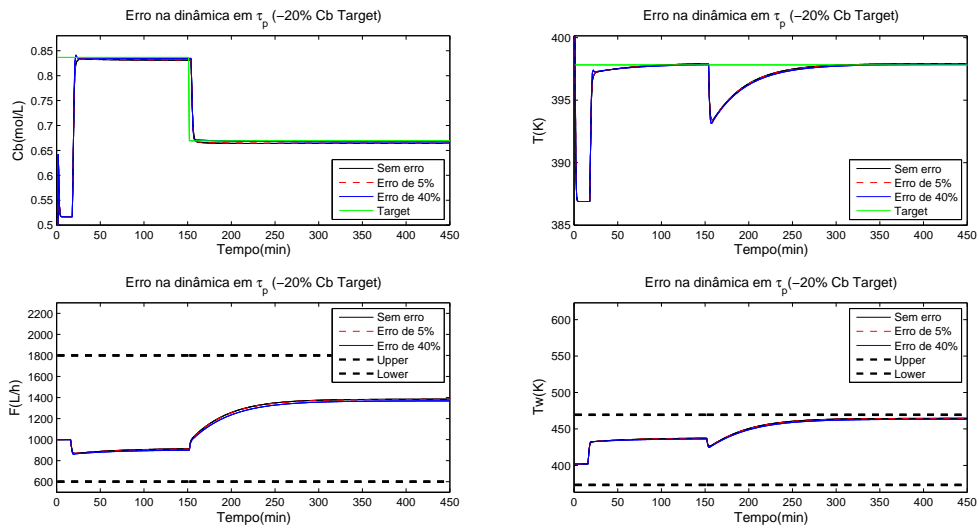


Figura 4.17: NMPC proposto com erros no modelo dinâmico em τ_p para o problema servo. A malha de controle é fechada em $t=15$ min e o setpoint muda em $t=150$ min.




Figura 4.18: NMPC proposto com erros no modelo dinâmico em ϵ para o problema servo. A malha de controle é fechada em $t=15$ min e o setpoint muda em $t=150$ min.

A Figura 4.19 mostra o desempenho do NMPC ao utilizar modelos estáticos com erros de modelagem para rejeitar perturbações na composição de alimentação. Este cenário demonstra que o controlador não consegue levar a planta para os *setpoints* na presença de grandes erros de modelagem. A baixa performance do controlador é explicada pela perda da vazão de alimentação como variável manipulada ao atingir o limite de mínimo, deixando o controlador com apenas um grau de liberdade para controlar duas variáveis controladas. Sendo assim, os resultados ilustram, similar ao problema servo, que o controlador tem baixo desempenho para rejeitar perturbações na presença de grandes erros de modelagem para descrever o estado-estacionário do processo.

As Figuras 4.20 e 4.21 mostram o desempenho do NMPC proposto em rejeitar distúrbios na composição de alimentação na presença de erros de modelagem para representar a dinâmica do processo em τ_p e ϵ , respectivamente. A análise dos resultados permite concluir que os erros de modelagem na representação da dinâmica do processo não ocasionam perda de performance do controlador.




Figura 4.19: NMPC proposto com erros no modelo estático para o problema regulatório. A malha de controle é fechada em $t=15$ min e a perturbação ocorre em $t=150$ min.




Figura 4.20: NMPC proposto com erros no modelo dinâmico em τ_p para o problema regulatório. A malha de controle é fechada em $t=15$ min e a perturbação ocorre em $t=150$ min.

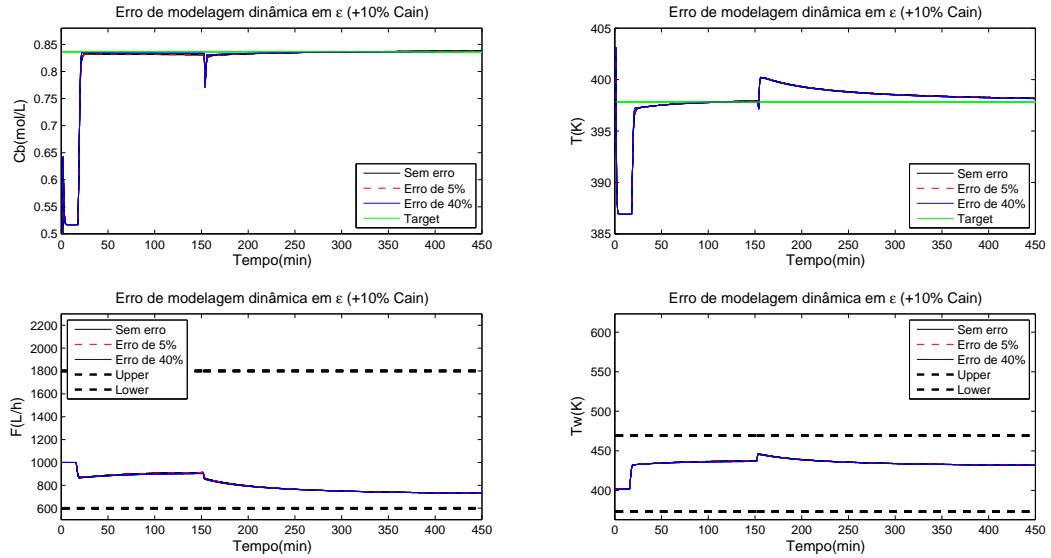


Figura 4.21: NMPC proposto com erros no modelo dinâmico em ϵ para o problema regulatório. A malha de controle é fechada em $t=15$ min e a perturbação ocorre em $t=150$ min.

4.1.4 Comparação entre o controlador NMPC usando o modelo proposto e um algoritmo MPC adaptativo

A Figura 4.22 ilustra uma comparação entre o algoritmo NMPC usando o modelo proposto, resultando em um problema não linear (NLP) a ser resolvido, e a estratégia MPC adaptativa, em que um problema de programação quadrática (QP) é resolvido. Os resultados demonstram que ambas as estratégias gastam o mesmo tempo computacional para resolver o problema de controle, entretanto, o modelo NMPC utilizando o modelo analítico proposto apresentou melhor desempenho do que o modelo MPC adaptativo para manter as variáveis controladas em seus respectivos *setpoints*. Uma das explicações possíveis seria que o modelo não linear teria capacidade em descrever a predição do comportamento da planta ao longo de todo o horizonte de controle, de forma mais fidedigna. Enquanto, o modelo adaptativo consiste em um modelo linear que é atualizado apenas no instante inicial da trajetória e não ao longo de todo o horizonte de controle, dessa forma haveria um desvio entre a predição do modelo e o real comportamento do processo.

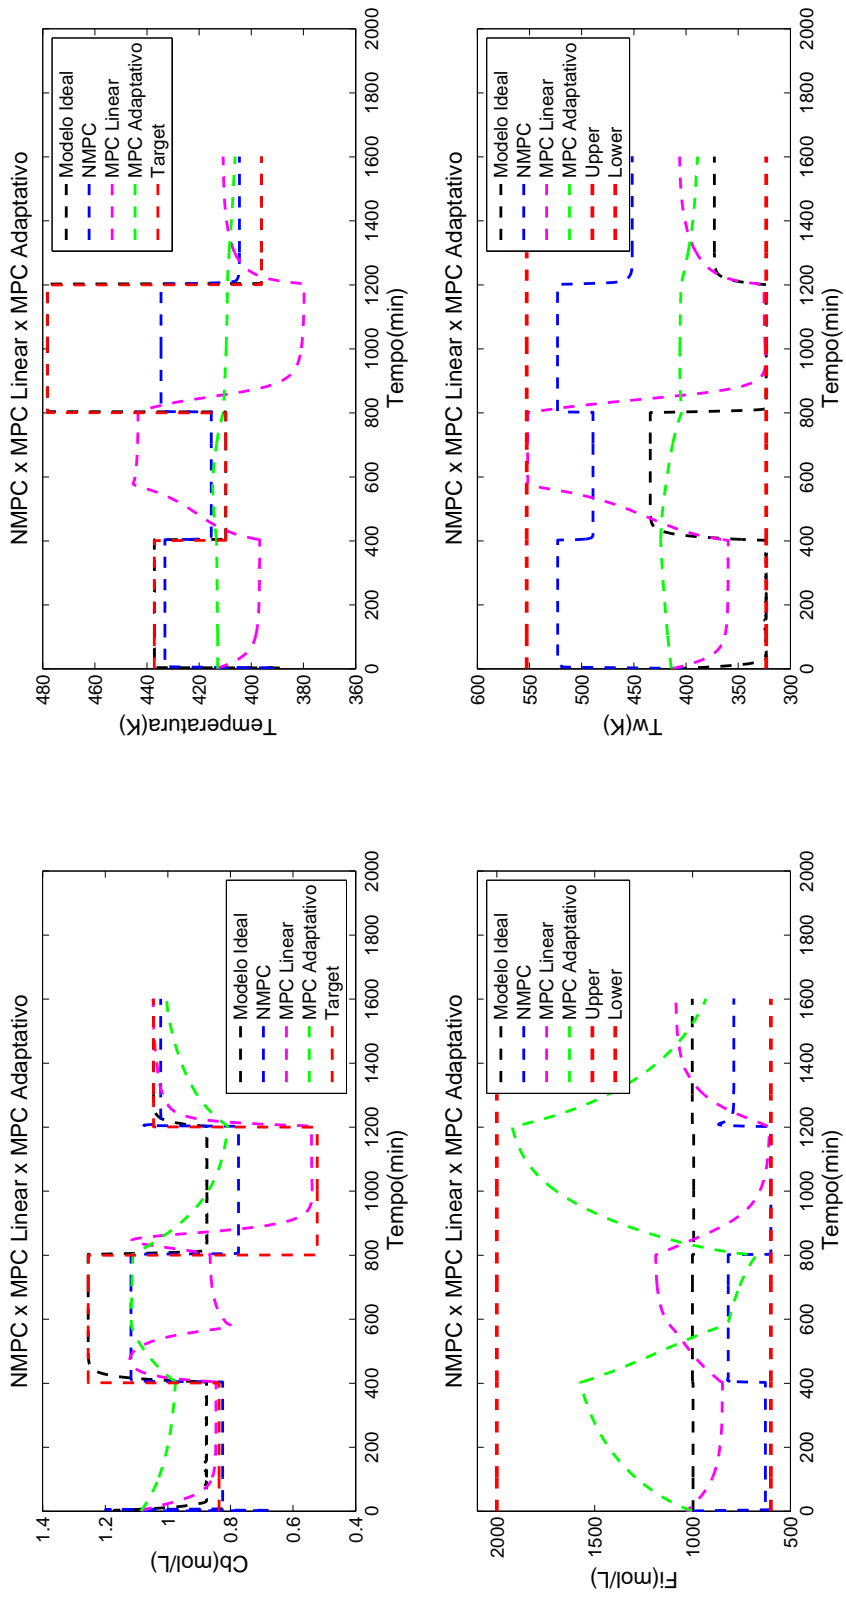


Figura 4.22: Comparação entre o NMPC com o modelo proposto e o MPC adaptativo.

4.1.5 Estudo de caso do desempenho do NMPC proposto na presença de perturbações não-medidas na vazão de fluido de resfriamento

A Figura 4.23 mostra o desempenho do NMPC para controlar a composição C_b e a temperatura frente a perturbações não-medidas na vazão de fluido de resfriamento. O estudo de caso foi realizado com dois tipos de perturbações não-medidas, aleatória e constante, aplicadas no instante de tempo $t = 200$ min. Os resultados comprovam o que já se era esperado, a ação *feedback* do controlador consegue eliminar os erros de modelagem ocasionados por perturbações não-medidas de caráter constante. Porém, se o comportamento dessas perturbações que não estão modeladas no problema de controle for aleatório, a performance do controlador é fortemente impactada, não conseguindo manter as variáveis controladas nos alvos sugeridos.

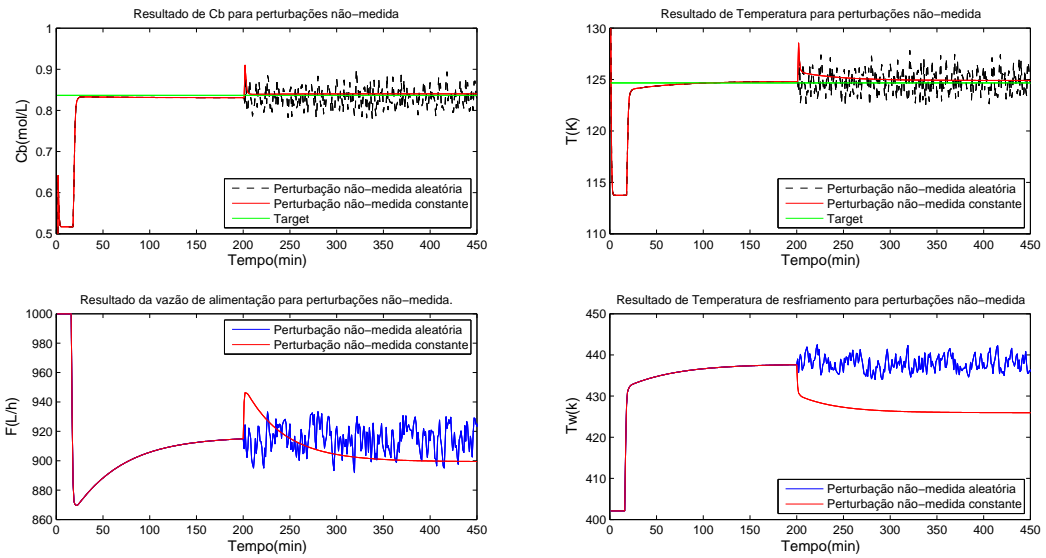


Figura 4.23: Resultados do NMPC proposto para rejeitar perturbações não medidas na temperatura do fluido de refriamento no instante $t = 200$ min.

4.1.6 Integração do NMPC proposto com uma camada de otimização

As Equações 4.9 a 4.15 descrevem a formulação do problema de otimização. O objetivo é maximizar a produção de C_b no estado estacionário, enviando esses *setpoints* para a camada de controle, representada pela Equação 3.1.

$$\max_{\underline{u}} C_b \tag{4.9}$$

Sujeito a:

$$0 = \frac{F}{V}(C_{a_{in}} - C_a) - K_1(T) C_a - K_3(T) C_a^2 \quad (4.10)$$

$$0 = -\frac{F}{V} C_b + K_1(T) C_a - K_2(T) C_b \quad (4.11)$$

$$0 = -\frac{1}{\rho C_p} [K_1(T) C_a (-\Delta H_{R_{AB}}) + K_2(T) C_b (-\Delta H_{R_{BC}}) + K_3(T) C_a^2 (-\Delta H_{R_{AD}})] + \frac{F}{V}(T_{in} - T) + \frac{K_w A_R}{\rho C_p V}(T_w - T) \quad (4.12)$$

$$K_i(T) = K_{i0} \exp\left(-\frac{E_i}{RT}\right) \quad (4.13)$$

$$\underline{u}_{min} \leq \underline{u} \leq \underline{u}_{max} \quad (4.14)$$

$$\underline{y}_{min} \leq \underline{y} \leq \underline{y}_{max} \quad (4.15)$$

Sendo, as Equações 4.10 a 4.12 para representar o comportamento do estado-estacionário do processo, enquanto a reformulação do problema de otimização com as Equações 4.1 a 4.4 são a formulação do problema de otimização dinâmica.

O problema de otimização consiste na maximização da produção de C_b sujeita a restrições nas variáveis manipuladas e controladas. A Figura 4.24 mostra uma boa performance do NMPC proposto em conduzir a planta para os *setpoints* enviados pela camada de otimização, resultando em um pequeno *offset* entre elas. É importante descrever que a estratégia de controle adotada aplica na planta apenas a primeira ação do horizonte de controle, reduzindo impactos que poderiam ser ocasionados por erros de modelagem ou pela presença de perturbações não-medidas.

As Figuras 4.25 e 4.26 ilustram uma comparação entre a otimização usando o modelo rigoroso e o modelo proposto. A otimização com o modelo proposto apresenta uma redução de 60% do tempo computacional gasto para resolver o problema de otimização com o modelo rigoroso, porém sem apresentar perda de desempenho, mostrando que a parte estática do modelo proposto é adequada para uso em técnicas de otimização de estado estacionário.

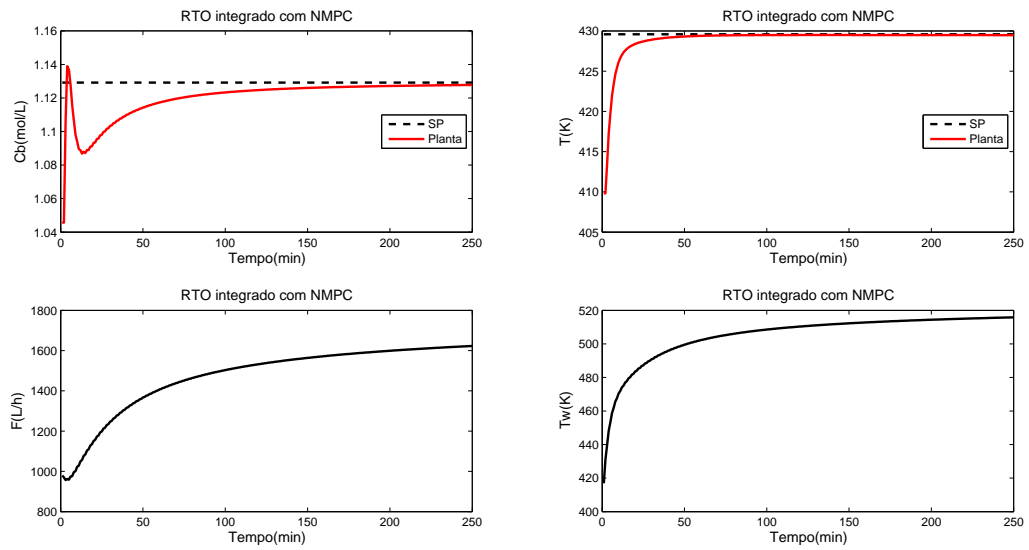


Figura 4.24: Resultado do NMPC proposto com a camada de otimização

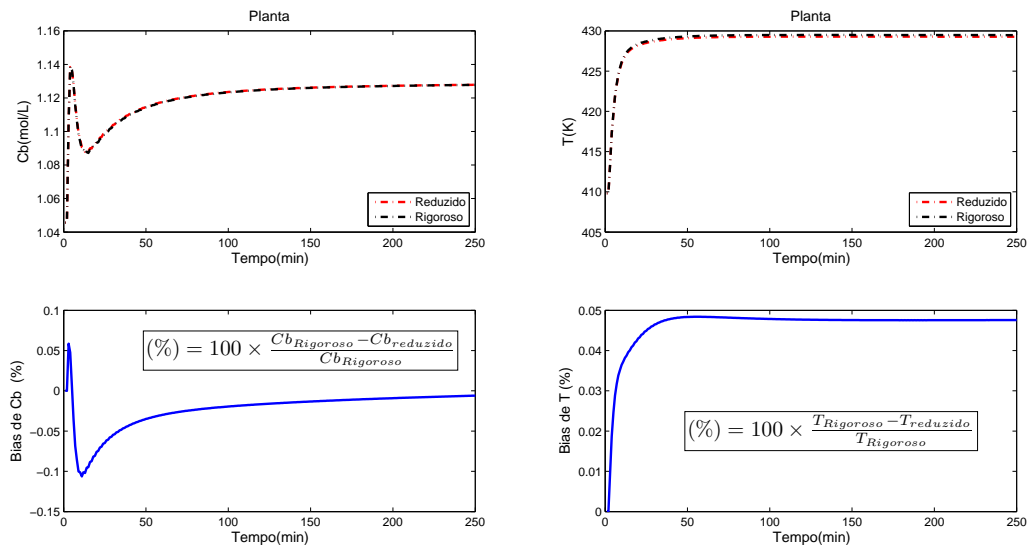


Figura 4.25: Comparação entre a otimização usando modelo estáticos com o modelo multi-paramétrico proposto e o modelo rigoroso




Figura 4.26: Comparação entre os alvos da otimização usando modelo estáticos com o modelo multi-paramétrico proposto e o modelo rigoroso

A Figura 4.27 ilustra o desempenho do algoritmo proposto integrado com uma camada de otimização dinâmica, em que o C_b é maximizado ao longo de toda a trajetória. Os resultados foram comparados com a estratégia de otimização usando modelos de estado-estacionário e com a estratégia de otimização dinâmica sem a camada de controle NMPC. De acordo com a Tabela 4.4, todas as soluções apresentam pontos ótimos próximos, sendo a estratégia DRTO+NMPC a que obteve o maior C_b entre as estratégias. A estratégia apenas com a camada de DRTO conduziu a planta para o *setpoint* mais rápido do que as outras estratégias, porém apresentou maior *overshooting*. Conclui-se pelos gráficos da figura, que a camada de NMPC consegue conduzir a planta pela trajetória sugerida na camada de D-RTO, demonstrando que a solução da otimização dinâmica, obtida com modelos fenomenológicos, é realizável utilizando o modelo proposto.

Tabela 4.4: Comparação entre as estruturas de otimização

Abordagem	$C_b[mol/L]$	$C_{b_{target}}[mol/L]$	$T[K]$	$T_{Target}[K]$
DRTO	1, 1290	1, 1308	428, 31	429, 37
DRTO+NMPC	1, 1297	1, 1357	427, 17	429, 33
RTO+NMPC	1, 1281	1, 1293	429, 44	429, 57




Figura 4.27: Comparação entre os resultados obtidos através de otimização dinâmica e os obtidos com otimização utilizando modelos estáticos.

4.1.7 Considerações finais

O desafio para aplicar estratégias NMPC é obter modelos que descrevam o comportamento do processo e cujo tempo computacional gasto em cada ciclo de controle permita uma frequência razoável de atuação do controlador em ambientes industriais. Modelos não lineares que acarrentem em alto custo computacional para resolver o problema de controle podem ocasionar soluções degeneradas, em que a solução obtida já não é mais compatível com a condição operacional da planta do instante em que o controlador iniciou o ciclo de controle. Este fato pode resultar em condições de instabilidade para o processo.

Neste contexto, uma metodologia para obter modelos analíticos visando algoritmos NMPC foi proposta, evitando perda de acurácia por conta de aproximações numéricas. O modelo analítico reduz a complexidade computacional enfrentada em aplicações de NMPC voltadas para uso em tempo real, mostrando ser promissora para problemas de grande escala.

A comparação entre o NMPC baseado no modelo proposto e o MPC adaptativo, em que apenas o ganho do estado-estacionário é atualizado em tempo real com as condições operacionais no início do ciclo de controle, ilustra que o NMPC proposto apresenta melhor desempenho na tarefa de conduzir a planta até os alvos sugeridos, sem ocasionar nenhum esforço computacional adicional ao da estratégia adaptativa.

Um estudo de erros de modelagem da parte estática e da parte dinâmica do problema foi realizado. Este estudo mostrou que o desempenho do controlador é muito mais afetada por erros na parte estática do modelo do que na parte dinâmica, principalmente quando se trata de patamares elevados de erro. Além disso, a presença de perturbações não-medidas, como por exemplo a temperatura do fluido de resfriamento, pode comprometer muito o desempenho do controlador em manter a planta nos alvos.

Conclui-se pelos resultados apresentados nesse capítulo, que o modelo proposto é bem-sucedido em conduzir o processo através da trajetória ótima calculada na camada de otimização dinâmica (D-RTO). Este fato permite afirmar que o modelo proposto descreve de forma acurada o comportamento da planta, sem degenerar a solução ótima obtida com modelos rigorosos, porém com menor esforço computacional, abrindo espaço para uso em aplicações industriais de maior dimensão.

4.2 Caso I - Aplicação do NMPC proposto em um processo de produção de óleo *offshore* modelado no EMSO

Nesta seção o NMPC proposto é aplicado na simulação de uma unidade de produção de óleo *offshore* do sistema Petrobras. A simulação da plataforma de produção foi desenvolvida no ambiente de modelagem, simulação e otimização (EMSO) (SOARES e SECCHI, 2003)

Na próxima seção é apresentada uma metodologia de identificação para obter o modelo analítico que descreve o processo *offshore*. Os resultados do NMPC aplicado ao processo de produção *offshore* mostram a capacidade do algoritmo proposto em mitigar os impactos causados por regimes golfantes de produção, além de manter a produção dentro das especificações de processo e, quando possível, conduzir a planta de processamento de óleo para a condição operacional ótima.

4.2.1 Desenvolvimento do modelo dinâmico

Processos de produção de óleo *offshore* podem ser tipicamente divididos em 4 seções: Sistema *subsea*, o qual consiste em poços submarinos, *pipeline* e *risers*; Sistema de *topside*, que contém os equipamentos de separação multifásica dos sistemas óleo, água e gás; Sistema de tratamento de água, o qual especifica a quantidade de óleo na água descartada no mar (TOG); Unidade de Compressão de gás, cuja finalidade consiste em recuperar a pressão de exportação do gás e a pressão para injeção de *gas-lift*.

Existem na literatura trabalhos de modelagem dinâmica de processos de produção de óleo *offshore* baseado em princípios fenomenológicos. Como por exemplo, modelos para descrever o comportamento dinâmico da coluna de produção acoplado com injeção de *gas-lift* (FOSS *et al.*, 2008; HANSEN *et al.*, 2012), modelos para descrever o comportamento do escoamento no *flowline* e *riser* (MEGLIO, 2011), modelos compreendendo desde o poço, o *flowline* e o *riser* (JAHANSHAHI, 2013), e modelos que incluem também o separador trifásico (RIBEIRO *et al.*, 2016). A característica mais importante que esses modelos devem ter é a capacidade de descrever as golfadas, como por exemplo, golfadas formadas no anular de injeção de *gas-lift*, golfadas de *case-heading* e golfadas ocasionadas pela topografia do leito-marinho que favorecem o acúmulo de gás. Além disso, *solvers* eficientes para a integração do sistema dinâmico é outra característica importante a ser considerada, principalmente quando o foco for aplicações em tempo real.

Nesse contexto, foi modelado no ambiente de modelagem e simulação do EMSO a planta de processamento da plataforma integrada com 3 poços de produção de

óleo com elevação artificial, sendo um deles em condição de fluxo golfante. A vazão de injeção de *gas-lift* e a abertura da válvula *choke* são variáveis manipuladas do problema de controle. O principal objetivo é estabilizar a vazão de óleo processada na planta de processamento da plataforma, evitando eventos de parada não-programada. Além disso, é importante manter a quantidade de água e sedimentos na vazão de óleo produzida (BSW) e a quantidade de óleo na água descartada (TOG) dentro das especificações de qualidade da planta, sendo assim, é adicionada o nível de interface do vaso de separação trifásico como uma das principais variáveis de processo para manter o BSW e o TOG dentro dos limites permitidos.

4.2.2 Descrição das unidades de processamento de óleo e de compressão de gás

A Figura 4.28 mostra a unidade de processamento de óleo da plataforma modelada no *software* EMSO. A vazão de fluido vindo dos poços submarinos consiste em uma mistura trifásica que chega na planta de processamento no vaso de separação gravitacional, primeiro equipamento, onde a mistura é separada em fase gasosa, que é direcionada para a unidade de compressão da plataforma, fase aquosa, que é direcionada para a planta de tratamento de água, cujo objetivo é retirar a quantidade de óleos e graxas (TOG) presente, de forma a enquadrar a água descartada no mar dentro dos requisitos ambientais definidos pelas agências reguladoras. A fase oleosa da saída do separador gravitacional é direcionada para o segundo equipamento, chamado degaseificador, onde parte do gás ainda dissolvido é removido. O óleo que deixa o degaseificador é direcionado para o tratador eletrostático, onde parte da água ainda dissolvida no óleo é removida e direcionada para o início do processo. Após essa etapa é adicionada uma pequena vazão de água ao óleo na saída do primeiro tratador eletrostático, o objetivo dessa adição de água de baixa salinidade é reduzir a salinidade da água presente no óleo, além de aumentá-la para uma fração mínima de água, de forma a ser possível o tratamento no segundo estágio de degaseificação e separação eletrostática. É preciso uma fração mínima de água no óleo para a separação da água por corrente eletrostática. O óleo na saída do segundo estágio de separação eletrostática já está com o BSW especificado e em condições de ser exportado, por oleoduto ou navio aliviador. A seção de processamento de óleo foi simulada com a estratégia de modelos *blackoils* (HUAN, 1985), que consiste em uma mistura multifásica representada por três componentes: água, gás e óleo.

A modelagem utilizada na planta de processamento de óleo necessita de apenas duas propriedades, massa molar e massa específica, para cada um dos componentes, óleo, água e gás. Essas duas informações são importantes, pois aparecem no equacionamento fenomenológico que descreve todo o processo de separação da planta de óleo. Portanto, nessa abordagem não há mudança de fase entre as fases, água, gás e óleo, que dependeriam da composição de componentes químicos em cada fase para a determinação do equilíbrio termodinâmico.

A Figura 4.29 ilustra a unidade de compressão da planta de processamento. Existe um limite mínimo de pressão para exportar o gás através do *pipeline*, assim como existem limites de máximo e de mínimo para a pressão de injeção de *gas-lift* e para a injeção no reservatório. Algumas vezes a planta de processamento recebe grandes vazões de gás a alta pressão, fenômeno esse conhecido por golfadas. Nessa situação, como medida emergencial de segurança e para evitar paradas de produção não-programadas, parte desse gás pode ser queimado no *flare*, incorrendo em perdas econômicas e problemas com órgãos ambientais. Nesse contexto, a planta foi projetada para ter uma operação flexível na destinação desse gás, enviando para *flare* apenas em último caso. Portanto, existem três destinos possíveis para o gás produzido: injeção por *gas-lift*, exportação através de gasoduto ou injeção no reservatório. Além disso, o CO₂ que vem do reservatório é separado através de um processo por membranas e esse CO₂ separado é reinjetado no reservatório através de uma unidade de compressão de CO₂, cujo objetivo é recuperar a pressão do gás para poder injetá-lo na pressão exigida pelo reservatório.

Os modelos usados na unidade de compressão são composicionais, pois a distribuição de componentes na vazão de gás é importante para calcular as propriedades termodinâmicas das mudanças de fase em cada equipamento do sistema de compressão da plataforma. Além disso, é importante ressaltar que, a simulação do processo foi construída baseada na metodologia *pressure-driven*, em que as vazões do balanço de massa são obtidas a partir do balanço de pressão entre os equipamentos de separação da planta de processamento do topside da plataforma.

THOMAZ (2017) aplicou uma estratégia de controle preditivo linear em simulação dinâmica da unidade de compressão ilustrada pela Figura 4.29. Os resultados mostram que a técnica é adequada para mitigar o impacto de perturbações externas ao sistema, mantendo a pressão do sistema estável, evitando queima de gás na tocha e paradas não-programadas da planta. Além disso, o MPC proposto consegue minimizar os gastos energéticos da compressão, através da redução das vazões de recirculação em cada estágio de compressão. Este resultado é importante, pois o maior custo econômico de processos de produção *offshore* está na etapa de compressão do gás produzido.




Figura 4.28: Fluxograma de processo da unidade de processamento de óleo offshore modelado no simulador EMSO (SOARES e SECCHI, 2003).




Figura 4.29: Fluxograma da unidade de compressão de gás *offshore* modelado no simulador EMSO (SOARES e SECCHI, 2003).

4.2.3 Formulação do problema de controle

O NMPC consiste na solução de um problema de controle ótimo não-linear discreto (NOCP), o qual é formulado a seguir:

$$\begin{aligned} \min_u J(u) = & \sum_{k=1}^{H_p} [y^{SP}(t_k) - y(t_k)]^T W [y^{SP}(t_k) - y(t_k)] + \sum_{k=1}^{H_c} \Delta u^T(t_k) S \Delta u(t_k) + \\ & \sum_{k=1}^{H_c} [u^{SP}(t_k) - u(t_k)]^T R [u^{SP}(t_k) - u(t_k)] \end{aligned} \quad (4.16)$$

Sujeito a :

$$y(t_k) = f^{NL}(u(t_k), d(t_k), y(t_0), t_k), \quad t_k \in [t_1, t_{H_p}] \quad (4.17)$$

$$u_{min} \leq u(t_k) \leq u_{max} \quad (4.18)$$

$$y_{min} \leq y(t_k) \leq y_{max} \quad (4.19)$$

Em que $u(t_k) \in \mathfrak{R}^{n_u}$ e $d(t_k) \in \mathfrak{R}^{n_d}$ são as variáveis manipuladas e perturbações, respectivamente, com $u(t)$ descrito por uma função constante por parte, $\Delta u(t_k) = u(t_k) - u(t_{k-1})$, $y^{SP}(t_k) \in \mathfrak{R}^{n_y}$ é a trajetória de referência e $u^{SP} \in \mathfrak{R}^{n_u}$ é a trajetória de target para as variáveis manipuladas. Ambas as trajetórias podem ser definidas como solução de um problema de otimização em tempo real (RTO) ou como solução de um problema de otimização dinâmica (DRTO). H_p é o horizonte de predição, H_c é o horizonte de controle, e $y(t_0) \in \mathfrak{R}^{n_y}$ é a condição inicial da variável controlada no início do problema de controle. O modelo não linear é descrito na seção a seguir.

4.2.4 Determinação do modelo não linear

Neste trabalho, uma abordagem multiparamétrica descrita por RIBEIRO e SECCHI (2018) foi usada para descrever o comportamento não-linear de processos de produção de óleo offshore.

As Equações 4.20 a 4.23 mostram o modelo não-linear usado para representar o processo de produção de óleo offshore, em que a Equação 4.21 é uma estrutura multiparamétrica para representar as condições de estado-estacionário e a Equação 4.23 é uma estrutura analítica para representar o comportamento dinâmico de processos de primeira-ordem, ou de segunda-ordem com tempo-morto (RIBEIRO e SECCHI, 2018).

$$y(t) = y^0 + [y^{ss}(u, d) - y^0] \otimes f(t) \quad (4.20)$$

$$y_j^{ss}(u, d) = \prod_{k=1}^{n_u} \sum_{i=0}^{n_1} C_{i,k,j}(d) (u_k)^i \quad (4.21)$$

$$C_{i,k,j}(d) = \prod_{l=1}^{n_d} \sum_{m=0}^{n_2} \alpha_{i,k,j,m,l}(d_l)^m \quad (4.22)$$

$$f_j(t) = 1 - \exp \left[\frac{-\varepsilon_j (t - \tau_{d_j})}{\tau_j} \right] \left\{ \cosh \left[\frac{\sqrt{\varepsilon_j^2 - 1}}{\tau_j} (t - \tau_{d_j}) \right] + \frac{\varepsilon_j}{\sqrt{\varepsilon_j^2 - 1}} \sinh \left[\frac{\sqrt{\varepsilon_j^2 - 1}}{\tau_j} (t - \tau_{d_j}) \right] \right\} \quad (4.23)$$

em que $j = 1, \dots, n_y$, \otimes é o produto de Hadarmat, veja apêndice C, $y(t) \in \mathfrak{R}^{n_y}$ é o vetor de variáveis controladas, $y^0 \in \mathfrak{R}^{n_y}$ é o vetor de valores iniciais para o horizonte de predição das variáveis controladas; $y^{ss} : R_u^n \times R_d^n \rightarrow R_y^n$ representa a relação entre as variáveis de entrada e a de saída para descrever o estado-estacionário, enquanto $f(t) \in \mathfrak{R}^{n_y}$ descreve o comportamento dinâmico do processo. A estrutura da Equação 4.20 permite obter de forma rápida o gradiente e a Hessiana analiticamente, reduzindo o esforço computacional para obter a solução do problema NLP.

Durante a etapa de identificação foi proposta uma metodologia descrita a seguir que combina variáveis de processo em variáveis auxiliares, melhorando a acurácia do modelo não-linear. A Figura 4.30 mostra o balanço de massa representado pelas variáveis auxiliares do modelo proposto. A Figura 4.31 ilustra o modelo baseado na estrutura de Hammerstein, sendo descrito pelas Equações 4.24 até 4.36 :

$$Oil_j^{SS} = f(GL_j, CK_j) \quad (4.24)$$

$$Oil_j(t, GL_j, CK_j) = Oil_j^0 + [Oil_j^{SS}(GL_j, CK_j) - Oil_j^0] f_j^{Oil}(t) \quad (4.25)$$

em que $j = 1, \dots, n$ e n são os números de poço, GL é a vazão de injeção de *gas-lift*, CK é a abertura da válvula *choke* de produção e Oil é a vazão de produção de óleo.

O balanço de massa no *manifold*, descrevendo as entradas no separador gravitacional, é dado por:

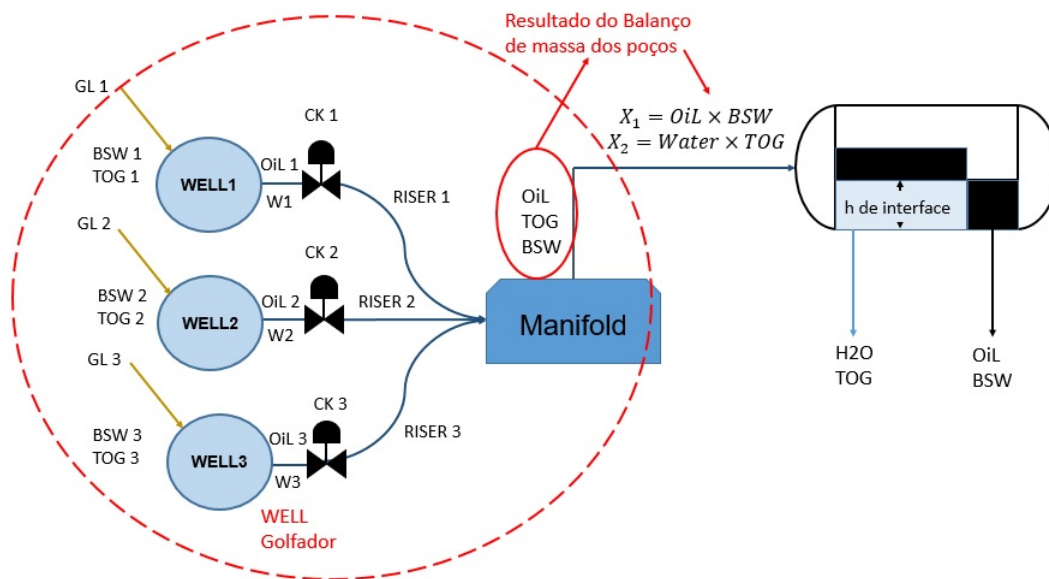


Figura 4.30: Esquema do balanço de massa do poço.

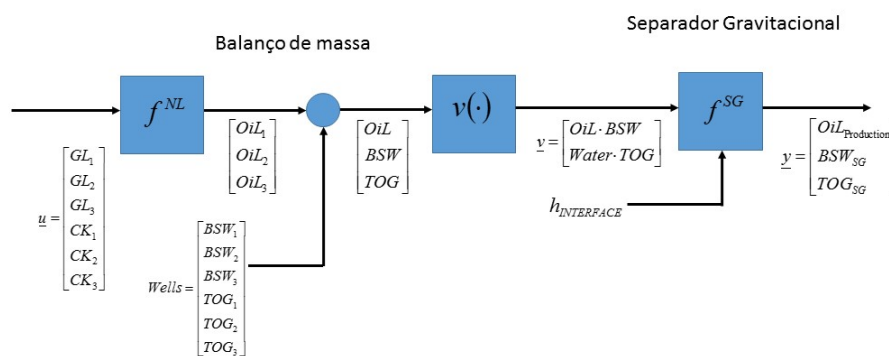


Figura 4.31: Representação do modelo proposto usando a estrutura de Hammerstein.

$$Oil = \sum_{j=1}^n Oil_j \quad (4.26)$$

$$Water = \sum_{j=1}^n W_j \quad (4.27)$$

$$BSW = \frac{\sum_{j=1}^n Oil_j BSW_j}{Oil} \quad (4.28)$$

$$TOG = \frac{\sum_{j=1}^n W_j TOG_j}{Water} \quad (4.29)$$

$$(4.30)$$

em que W_j é a vazão de água produzida por cada poço j , BSW_j são os sedimentos e a água presente na vazão de óleo chegando de cada poço j , e TOG_j é a concentração de óleo na vazão de água chegando de cada poço j .

Definindo as seguintes variáveis auxiliares:

$$\nu_1 = Oil \cdot BSW \quad (4.31)$$

$$\nu_2 = Water \cdot TOG \quad (4.32)$$

em que ν_1 representa a vazão de água presente na fase oleosa e ν_2 representa a vazão de óleo na fase aquosa, respectivamente. As funções multiparamétricas, Equação 4.21, são escritas em termos dessas variáveis e do nível de interface água-óleo, h_{in} :

$$BSW_{SG}^{SS} = f(\nu_1, h_{in}) \quad (4.33)$$

$$TOG_{SG}^{SS} = f(\nu_2, h_{in}) \quad (4.34)$$

em que BSW_{SG}^{SS} e TOG_{SG}^{SS} são os valores de estado-estacionário de BSW e TOG nas vazões de óleo e água deixando o separador gravitacional, respectivamente. Reescrevendo a Equação 4.20 em termos das variáveis manipuladas e controladas, resulta em:

$$BSW_{SG}(t, \nu_1, h_{in}) = BSW^0 + [BSW_{SG}^{SS}(\nu_1, h_{in}) - BSW^0]f_{SG}^{BSW}(t) \quad (4.35)$$

$$TOG_{SG}(t, \nu_2, h_{in}) = TOG^0 + [TOG_{SG}^{SS}(\nu_2, h_{in}) - TOG^0]f_{SG}^{TOG}(t) \quad (4.36)$$

A metodologia usada para obter o modelo descrito nas Equações 4.20 até 4.23 consiste em: (1) Seleção da estrutura mais adequada para descrever o comportamento dinâmico do processo através de testes de identificação, usando funções de primeira e segunda ordem, com ou sem tempo morto, até se obter o modelo de melhor desempenho em descrever a planta; (2) Determinação dos parâmetros da estrutura de Hammerstein.

A Figura 4.32 mostra a predição calculada pelo modelo proposto para cada ação de controle. É possível observar a característica adaptativa do modelo, ou seja, o modelo é atualizado para descrever o comportamento do processo com as condições operacionais obtidas via ação de controle anterior. Cada curva na figura representa uma nova trajetória de predição obtida para a condição operacional atual, mostrando a adaptabilidade do modelo para descrever as não-linearidades do processo. Os parâmetros do modelo, Equação 4.20 a 4.23, são calculadas com as condições operacionais de cada ciclo de controle. A próxima seção mostra o resultado da aplicação da estratégia NMPC no estudo de caso que representa uma planta real de processamento de óleo *offshore*.




Figura 4.32: Trajetória de predição calculada pelo modelo proposto para cada degrau nas variáveis de entrada.

4.2.5 Resultados e discussões do caso I

O estudo de caso desse capítulo consiste na aplicação de uma estratégia NMPC em uma simulação de uma planta real de processamento de óleo *offshore*, cujo objetivo do controlador é mitigar os impactos causados por regimes de escoamento golfante e, quando possível, conduzir a planta até um ponto ótimo operacional. Neste contexto, foram escolhidas como variáveis manipuladas as variáveis de processo que apresentam maior relação com esses objetivos. A Figura 4.33 mostra uma correlação não-linear entre a vazão de injeção de *gas-lift* e a vazão de produção de óleo, sendo portanto, uma boa escolha junto com a abertura da válvula *choke* de produção como variáveis manipuladas para controle dessa vazão. Outra tarefa importante do algoritmo NMPC é garantir que o BSW no óleo exportado e o TOG na água descartada estejam dentro dos limites de especificação de produção. A vazão de produção tem efeito em ambos, por exemplo, se a vazão de produção de óleo é elevada, o tempo de residência será baixo e, conseqüentemente, a separação será menos eficiente. Sendo assim, é importante ter um grau de liberdade a mais para ajustar o BSW e o TOG dentro dos limites de especificação, que neste caso é o nível de interface água e óleo da câmara de separação de água. Outro ponto importante, é mapear todas as variáveis que são perturbações e impactam no enquadramento das especificações, como por exemplo o TOG e o BSW proveniente de cada poço. Portanto, na modelagem em questão, são considerados o BSW e o TOG de cada poço, além dos regimes de vazão de produção golfante, como perturbações ao processo que podem impactar na performance do controlador.

O modelo não-linear proposto para representar o comportamento do estado-estacionário da produção de óleo *offshore* é descrito pelas Equações 4.37 a 4.39.

$$\begin{aligned}
 Oil_j^{ss}(GL_j, CK_j) = & C_{1,j} + C_{2,j} GL_j + C_{3,j} CK_j + C_{4,j} GL_j CK_j + C_{5,j} GL_j^2 + \\
 & C_{6,j} CK_n(1).^2 + C_{7,j} GL_j CK_j^2 + C_{8,j} GL_j^2 CK_j + C_{9,j} GL_j^3 + C_{10,j} CK_j^3 + \\
 & C_{11,j} GL_j CK_j^3 + C_{12,j} GL_j^3 CK_j + C_{13,j} GL_j^4 + C_{14,j} CK_j^4 \quad j = [1, 2, 3] \quad (4.37)
 \end{aligned}$$

em que Oil_j^{ss} é a vazão de produção de óleo no estado-estacionário, GL_j é a vazão de injeção de gas-lift e CK_j a abertura da válvula *choke* de produção no j -ésimo poço. Tabela 4.5 mostra os parâmetros da Equação 4.37.

Tabela 4.5: Parâmetros do modelo estático da produção de óleo.

Oil_j^{ss}	Well $j = 1$	Well $j = 2$	Well $j = 3$
$C_{1,j}$	0,1296	0,1296	1,5245
$C_{2,j}$	1,5332	1,6332	-1,1879
$C_{3,j}$	1,3931	1,8931	-4,6642
$C_{4,j}$	-1,3462	-1,4462	-0,9213
$C_{5,j}$	-0,6235	-0,8235	1,8046
$C_{6,j}$	-0,4192	-0,8192	10,1092
$C_{7,j}$	-0,1757	-0,3757	3,9526
$C_{8,j}$	-0,8668	-0,8668	-1,2630
$C_{9,j}$	-1,6269	-1,6269	-0,7334
$C_{10,j}$	-0,1983	-0,3983	-10,6522
$C_{11,j}$	0,3394	0,3394	-1,8312
$C_{12,j}$	0,9551	0,9551	-0,1433
$C_{13,j}$	0,8803	1,8803	0,3467
$C_{14,j}$	0,0913	0,0913	4,0649

$$BSW_{SG}^{ss}(\nu_1, h_{in}) = C_1 + C_2 \nu_1 + C_3 h_{in} + C_4 \nu_1 h_{in} + C_5 \nu_1^2 + C_6 h_{in}^2 + C_7 \nu_1 h_{in}^2 + C_8 \nu_1^2 h_{in} \quad (4.38)$$

$$TOG_{SG}^{ss}(\nu_2, h_{in}) = C_1 + C_2 \nu_2 + C_3 h_{in} + C_4 \nu_2 h_{in} + C_5 \nu_2^2 + C_6 h_{in}^2 + C_7 \nu_2 h_{in}^2 + C_8 \nu_2^2 h_{in} \quad (4.39)$$

em que BSW_{SG}^{ss} é o óleo deixando o separador gravitacional e TOG_{SG}^{ss} é a quantidade de óleo na água descartada, ν_1 e ν_2 são as variáveis auxiliares descritas pelas Equações 4.31 e 4.32. Tabela 4.6 mostra os parâmetros das Equações 4.38 e 4.39.

Tabela 4.6: Parâmetros dos modelos estáticos de BSW_{SG}^{ss} e do TOG_{SG}^{ss}

	BSW_{SG}^{ss}	TOG_{SG}^{ss}
C_1	-0,0239	0,4528
C_2	1,1503	0,7352
C_3	-0,0172	-0,9963
C_4	0,2670	-0,3575
C_5	-0,2032	-0,1560
C_6	0,0298	0,5074
C_7	0,1009	0,1435
C_8	-0,3892	0,0240

As Tabelas 4.7 e 4.8 mostram os parâmetros do modelo dinâmico, descritos pelas funções, $f_j^{Oil}(t)$, $f_{SG}^{BSW}(t)$ e $f_{SG}^{TOG}(t)$.

Tabela 4.7: Parâmetros dos modelos dinâmicos para a produção de óleo em cada poço.

$f_j^{Oil}(t)$	ε_j	$\tau_j[s]$
Well $j = 1$	1,9302	1786,3
Well $j = 2$	6,1533	473,3
Well $j = 3$	0,8159	5336,7

Tabela 4.8: Parâmetros dos modelos dinâmicos da produção de BSW e TOG.

Parâmetros	ε_j	$\tau_j[s]$
$f_{SG}^{BSW}(t)$	2,714	78,590
$f_{SG}^{TOG}(t)$	7,158	12691,321

A Figura 4.33 ilustra a produção de óleo como função da vazão de injeção de *gas-lift* e da abertura da válvula de choke de produção, apresentando correlação não-linear entre a produção de óleo e a vazão de injeção de *gas-lift*. As Figuras 4.34 e 4.35 ilustram o comportamento do *TOG* e do *BSW*, respectivamente, como funções das variáveis auxiliares em diferentes níveis de interface água-óleo. Os resultados mostram que o modelo proposto descreve o regime de estado-estacionário da produção de óleo, *BSW* e *TOG*, de forma acurada para uso em técnicas de NMPC.




Figura 4.33: Comparação entre o estado-estacionário descrito pelo modelo e o descrito pela planta para a produção de óleo.

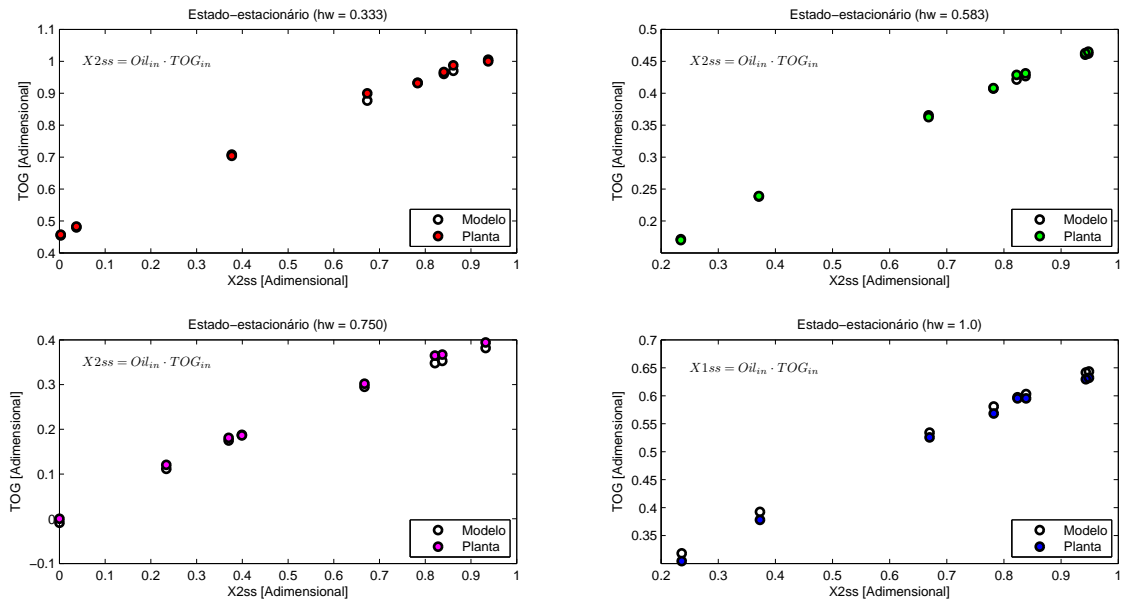


Figura 4.34: Comparação entre os pontos de estado-estacionário obtidos pelo modelo proposto e pela planta para o TOG na vazão de água descartada.




Figura 4.35: Comparação entre os pontos de estado-estacionário obtidos pelo modelo proposto e pela planta para o BSW na vazão de produção de óleo.

As Figuras 4.36 até 4.42 mostram uma comparação entre o controlador NMPC usando o modelo não linear proposto com uma estratégia QDMC tradicional que usa modelos lineares obtidos a partir de testes de resposta ao degrau na planta (GARCIA e MORSHEDI, 1986). Os resultados ilustram que o NMPC com o modelo proposto apresentou melhor performance em conduzir a planta para o *setpoint* da produção de óleo do que a estratégia QDMC tradicional. O modelo proposto foi capaz de descrever o comportamento não linear do processo através de variáveis auxiliares, Equações 4.31 e 4.32. Vale comentar que o modelo proposto não pôde descrever os comportamentos das variáveis *BSW* e o *TOG* sem adotar a estratégia de variáveis auxiliares, ou seja, diretamente com as variáveis de processo.

A Figura 4.37 mostra o NMPC proposto estabilizando a planta no alvo sugerido, eliminando o regime oscilatório ocasionado por um dos poços golfantes. Por outro lado, o QDMC com modelos lineares não consegue eliminar os impactos das golfadas provenientes de um dos poços, muito provavelmente, por conta dos erros de modelagem presentes na tentativa de descrever um comportamento não linear do processo por modelos lineares.

Um dos objetivos do controlador é manter as especificações de qualidade, *BSW* e *TOG*, dentro dos limites de processo. Nesse contexto, as Figuras 4.38 e 4.39 ilustram os desempenhos do NMPC e do QDMC durante a perturbação no *TOG* vindo de um dos poços. Os resultados comprovam que o NMPC proposto consegue rejeitar bem a perturbação, mantendo as especificações dentro dos limites, porém o QDMC não conseguiu cumprir com êxito esse objetivo. Este baixo desempenho do QDMC pode ser explicado pelo fato do modelo linear usado no controlador não conseguir reproduzir a relação não linear entre as variáveis manipuladas, vazão de injeção de gás-lift, abertura da válvula de choke e nível de interface do separador gravitacional com as variáveis controladas, *BSW* e *TOG*.

As Figuras 4.40 até 4.42 ilustram as variáveis manipuladas obtidas como soluções do problema de controle para as estratégias de NMPC proposto e do QDMC. Na estratégia com modelo não linear é possível obter soluções para as variáveis manipuladas dentro dos limites de máximo e de mínimo, porém nas estratégias com modelo linear isso não é possível, pois as soluções da estratégia de controle QDMC levam a saturação de algumas das variáveis manipuladas, ocasionando perda de grau de liberdade para manter as variáveis controladas dentro dos limites ou nos *setpoints*.




Figura 4.36: Comparação entre as estratégias MPC linear e NMPC com modelo proposto para conduzir a vazão de produção de óleo aos setpoints sugeridos.




Figura 4.37: Comparação entre as estratégias de MPC com modelo linear e do NMPC proposto para mitigar golfadas.




Figura 4.38: Comparação entre as estratégias de MPC com modelo linear e do NMPC proposto para manter as especificações de *TOG* dentro dos limites.




Figura 4.39: Comparação entre as estratégias de MPC com modelo linear e do NMPC proposto para manter as especificações de *BSW* dentro dos limites.




Figura 4.40: Comparação das soluções do NMPC proposto e do QDMC para a vazão de injeção de gás-lift em cada poço.




Figura 4.41: Comparação das soluções do NMPC proposto e do QDMC para a abertura da válvula de choke de produção de cada poço.




Figura 4.42: Comparação das soluções do NMPC proposto e do QDMC para o nível de interface água-óleo do separador gravitacional.

4.2.6 Considerações finais do caso I

O modelo não linear proposto demonstrou ser eficiente em descrever o comportamento do estado-estacionário da vazão de óleo produzida, do BSW e do TOG. A estratégia de combinar os efeitos da vazão de produção de óleo e água com o BSW e o TOG, respectivamente, vindo dos poços em variáveis auxiliares foi bem-sucedido. A estratégia com o NMPC proposto teve desempenho muito melhor do que a estratégia MPC com modelos lineares, mostrando que estratégias MPC não são capazes de eliminar o regime oscilatório ocasionado por golfadas, assim como não são capazes de garantir as especificações de processo dentro dos limites de operação. Conclui-se com os resultados que o NMPC com o modelo proposto foi eficiente em mitigar os impactos das golfadas, garantir as especificações de BSW e TOG dentro dos limites de operação, mesmo na presença de perturbação no TOG proveniente de um dos poços. Além disso, o controlador conseguiu conduzir a planta até os *setpoints* sugeridos.

Outro resultado importante desse estudo de caso, foi o baixo custo computacional apresentado pela estratégia de NMPC proposta, aproximadamente 10 segundos por ciclo de controle, usando o Matlab em um computador com memória de 8GB e processador i7, para resolver um problema NLP com 7 variáveis manipuladas, 3 variáveis controladas e uma variável distúrbio. Essa é uma importante contribuição do trabalho, pois demonstra o potencial do algoritmo proposto para aplicações industriais.

4.3 Caso II - Aplicação do NMPC proposto em um processo de produção de óleo offshore nos ambientes de simulação EMSO e OLGA

Nesta seção é apresentada a aplicação da estratégia de NMPC proposto em um ambiente de simulação integrado dos simuladores EMSO (SOARES e SECCHI, 2003) e OLGA. A planta de processamento de óleo da plataforma foi simulada no ambiente de modelagem, simulação e otimização (EMSO) e integrada à modelagem da seção subsea do processo de produção (OLGA) que consiste em poços submarinos, *flowline* e *riser*.

4.3.1 Breve descrição do processo de produção de óleo offshore

A planta de processamento de óleo *offshore* foi modelada no simulador de processo EMSO (SOARES e SECCHI, 2003) e integrado ao simulador comercial OLGA. Foram simulados 4 poços submarinos com elevação artificial, *flowline* e *riser*, sendo um dos poços em regime de escoamento oscilatório devido à presença de golfadas. O escopo do controlador consiste nas seguintes variáveis manipuladas: abertura da válvula *choke* e da injeção de *gas lift* de cada um dos poços e o nível de interface do separador gravitacional, grau de liberdade com forte correlação para controlar as especificações de processo, BSW e TOG. O principal objetivo do controlador é estabilizar a planta de processamento de óleo, evitando paradas de produção não-programadas, principalmente as ocasionadas por alta pressão no sistema de compressão. Neste cenário, após garantir estabilidade operacional e havendo margem para otimização, o controlador buscará levar a planta para o ponto operacional ótimo sugerido, sempre acompanhando as especificações de processo BSW e TOG, de forma a mantê-las dentro dos limites de operação aceitáveis.

A planta de processamento de óleo e o sistema de compressão de gás são os mesmos modelos descritos na Seção 4.2.2. A principal diferença nesse estudo de caso foi o acoplamento desses modelos a um sistema com 4 poços submarinos modelados em simulador comercial para escoamento multifásico subsea (OLGA).

A Figura 4.43 mostra o sistema *subsea* simulado no ambiente de simulação OLGA, considerando desde o poço submarino com elevação artificial, *flowline* até o *riser*. A integração da modelagem do escoamento subsea em OLGA com a modelagem da planta de processamento no ambiente de simulação EMSO (SOARES e SECCHI, 2003) foi realizada através de comunicação OPC.




Figura 4.43: Simulação do sistema subsea no simulador OLGA.

4.3.2 Resultados e discussões do caso II

Nesta seção são apresentados os resultados da aplicação do NMPC proposto na simulação do processo de produção de óleo *offshore* modelada no ambiente de simulação integrado EMSO e OLGA.

A Figura 4.44 mostra a relação entre a produção *offshore* e a vazão de injeção de *gas-lift* usando o simulador de escoamento subsea OLGA.




Figura 4.44: Relação entre as vazões de óleo, gás e água com a vazão de injeção de *gas-lift*.

As Figuras 4.45 e 4.46 mostram o NMPC conduzindo a planta para o *setpoint*, eliminando o regime oscilatório causado pela presença de golfadas em um dos poços. Além disso, o controlador tem como um de seus objetivos manter as especificações de processo dentro dos limites de operação. Neste contexto, visando avaliar o desempenho do controlador, foi aplicado ao processo uma perturbação no *TOG* proveniente de um dos poços. Os resultados demonstraram que o controlador consegue rejeitar de forma eficaz a perturbação, mantendo as especificações dentro dos limites.

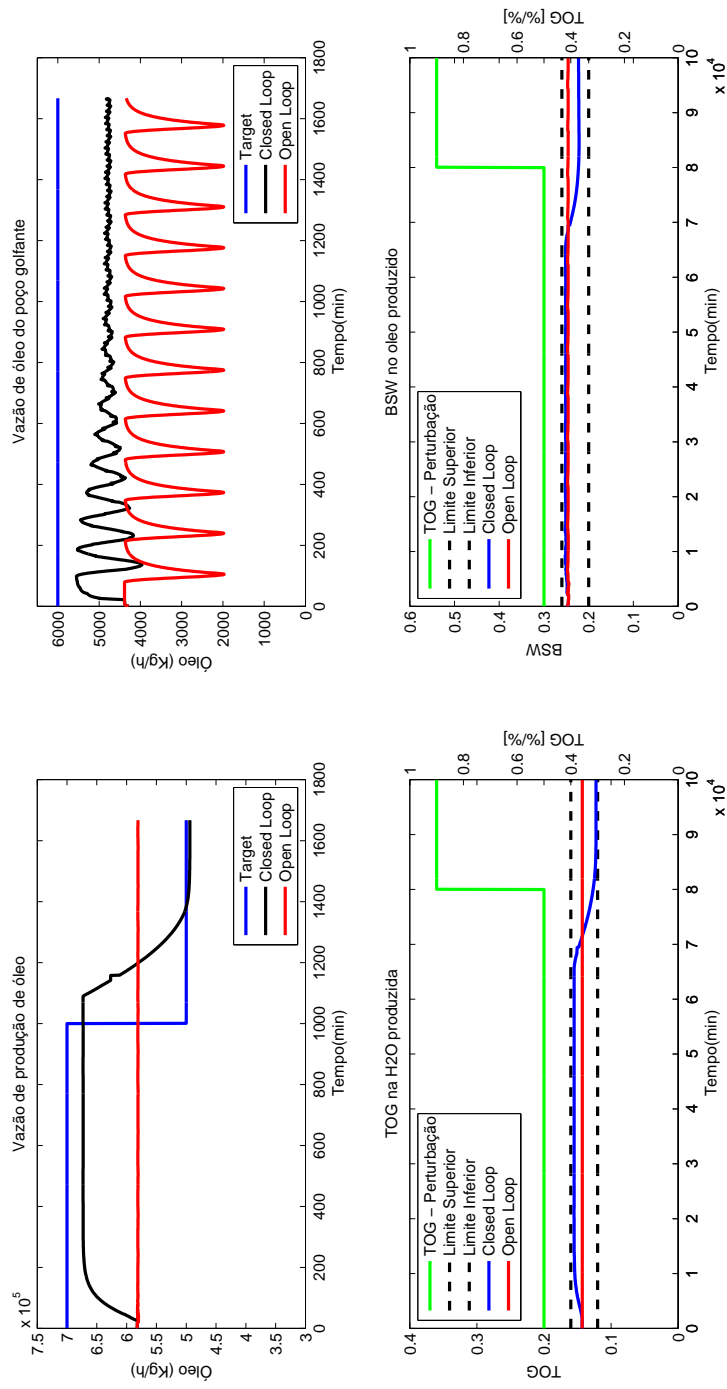


Figura 4.45: Resultados das variáveis controladas na aplicação da estratégia NMPC proposta em poços de produção de óleo *offshore*.




Figura 4.46: Resultados das variáveis manipuladas da aplicação do NMPC proposto em processo de produção de óleo *offshore*.

Neste ponto, o algoritmo proposto é comparado com estratégias de controle tradicionais para mitigação de golfadas, controle anti-golfadas (GODHAVN *et al.*, 2005) e controle PID recursivo. O objetivo é avaliar o desempenho do NMPC com o modelo proposto, usando como variáveis manipuladas a vazão de injeção de gás-lift e a abertura da válvula *choke*, para controlar a pressão no fundo do poço, PDG -*Permanent downhole gauge*, em um valor de mínimo. A condição de pressão mínima no fundo do poço ocasiona maior produção de óleo e gás, sendo portanto mais vantajosa economicamente, porém é uma condição de maior risco de instabilidade operacional, como resultado da presença de golfadas. Neste cenário, os algoritmos são avaliados pela capacidade de manter a pressão no fundo do poço em patamares menores, mas sem perder a estabilidade operacional.

- Estratégia de controle anti-golfadas (GODHAVN *et al.*, 2005)

O objetivo da estratégia de anti-golfadas é atuar na abertura da válvula *choke* para mitigar o impacto das golfadas no processo, mas sempre buscando a abertura máxima de *choke*, que ocasiona a maior produção. A Equação 4.40 descreve a estratégia.

$$\begin{aligned}
 u(k+1) &= u(k) + \alpha_1(PDG(k) - PDG(k-1)) + \\
 &\alpha_2(PDG(k-1) - PDG(k-2)) + \beta(u^{Otim} - u(k))
 \end{aligned}
 \quad (4.40)$$

em que α_1 e α_2 são os parâmetros da lei de controle responsáveis pela ação de controle para estabilizar o processo e β é o parâmetro de velocidade do algoritmo

para conduzir a abertura da válvula *choke* para o valor ótimo, u^{Otim} . Portanto, se $\alpha_{1,2} \gg \beta$ o algoritmo será mais conservador, sendo indicado para poços mais agressivos com golfadas severas. Por outro lado, se o processo tem comportamento mais estável, o indicado é usar $\beta \gg \alpha_{1,2}$, possibilitando maior velocidade ao algoritmo em alcançar a abertura ótima.

- Estratégia de controle PID-recursivo

O objetivo dessa estratégia é estabilizar a variação de pressão na cabeça do poço, PDG, mitigando as golfadas e, com isso, os riscos de instabilidade operacional. Porém, sem utilizar nenhum critério de otimização na formulação do problema de controle.

$$\begin{aligned} u(k) &= u(k-1) + \alpha_0 erro(k) + \alpha_1 erro(k-1) + \alpha_2 erro(k-2) & (4.41) \\ erro(k) &= SP - y(k) \\ y(k) &= PDG(k) - PDG(k-1) \end{aligned}$$

em que α_0 , α_1 e α_2 são parâmetros de sintonia do PID e $SP \simeq 0$. O valor de SP utilizado na lei de controle será o menor possível, de forma que $PDG(k) \simeq PDG(k-1)$, condição de regime estável. Sendo assim, comparando essa lei de controle com a do algoritmo anti-golfada e do NMPC proposto, é possível notar ausência de qualquer critério de otimização, mostrando apenas foco em estabilizar o processo.

As Figuras 4.47 a 4.49 ilustram um comparativo entre a estratégia de NMPC proposto e estratégias tradicionais da literatura para mitigação de golfadas. As estratégias apresentaram desempenhos similares, com a estratégia de anti-golfada apresentando mais picos oscilatórios do que as outras estratégias. Além disso, no estudo de caso com valores menores para o alvo de pressão no fundo do poço, reduzindo o patamar por um fator de 50 %, aumentando o erro do controlador e com isso buscando maior rentabilidade. A estratégia do NMPC proposto conseguiu melhor desempenho para estabilizar o PDG do que as outras estratégias, porém, estabilizou a pressão em maior patamar, o que ocasiona menor produção de óleo e gás, ou seja, em ponto operacional de menor rentabilidade. Conclui-se, portanto, a necessidade de aprofundar mais os estudos de sintonia do algoritmo proposto para esse exemplo, de forma a melhorar o desempenho da estratégia.




Figura 4.47: Comparação entre as estratégias de *Antislug* x PID-recursivo e o NMPC proposto.




Figura 4.48: Resultado da variável manipulada - Abertura da válvula de choke das estratégias de controle, NMPC, PID e *Antislug*.




Figura 4.49: Resultado da variável manipulada - Vazão de injeção de *gas-lift* das estratégias de controle, NMPC, PID e *Antislug*.

4.4 Caso III - Aplicação do NMPC proposto integrado com uma camada de Otimização a processos de produção de óleo *offshore*

Nesta seção é apresentado o estudo de caso da integração entre o NMPC proposto e a camada de otimização aplicados a um processo de produção *offshore*.

4.4.1 Formulação do problema de otimização

Os modelos propostos que descrevem o estado-estacionário do processo e são usados no problema de otimização estão descritos na Equação 4.42.

$$Y_j^{ss}(GL_j, CK_j, P_t) = \prod_{k=1}^3 \sum_{i=0}^9 C_{i,k,j} (u_k)^i \quad (4.42)$$

em que $Y_j^{ss} = [Oil_j^{ss}, Gas_j^{ss}, BHP_j^{ss}]$ são as produções de óleo e gás, e o consumo de energia no processo, respectivamente. $u = [GL_j, CK_j, P_t]$ descrevem os graus de liberdade do problema de otimização, sendo GL_j a injeção de *gas lift*, CK_j a abertura do *choke* do j-ésimo poço, e P_t a pressão na planta de processamento da plataforma.

A Equação 4.43 descreve como o problema de otimização foi formulado, em que as produções de óleo e gás compõem a receita e o consumo de energia representa o custo presente na função econômica.

$$\begin{aligned} \max_u (F_{obj}(u)) &= Profit - Cost - W \times Penalty \\ Profit &= \sum_{j=1}^n [K_j^{Oil} Oil_j^{ss} + K_j^{Gas} Gas_j^{ss}] \\ Cost &= \sum_{j=1}^m [K_j^{BHP} BHP_j] \\ Penalty &= \sum_{j=1}^n \max(GL_j - GL_j^{max}, 0) + \\ &\max\left(\sum_{j=1}^n GL_j - GL^{Total}, 0\right) \end{aligned}$$

Sujeito à:

$$\begin{aligned} GL_j &\leq GL_j^{max} \\ P^{min} &\leq P_t \leq P^{max} \\ BSW^{min} &\leq BSW \leq BSW^{max} \\ TOG^{min} &\leq TOG \leq TOG^{max} \end{aligned} \quad (4.43)$$

em que $[K_j^{Oil}, K_j^{Gas}]$ são os ganhos econômicos para cada poço j com unidade de medida $[\$/(\text{m}^3/\text{h})]$, K_j^{BHP} é o custo econômico de cada compressor j com unidade de medida $[\$/\text{kW}]$, e W é o parâmetro de sintonia do controlador.

4.4.2 Resultados e discussões do caso III

Nesta seção são ilustrados os resultados da aplicação do NMPC proposto integrado com a camada de otimização. A Figura 4.50 mostra a relação entre a produção com a pressão no *topside*, a qual é uma variável importante no problema de otimização.




Figura 4.50: Relação entre as vazões de óleo, gás e água com a pressão no *topside*.

As Figuras 4.51 e 4.52 ilustram a relação entre a pressão no *topside* com as vazões de óleo e gás produzidas, as especificações de BSW e TOG, e o consumo de energia. A pressão é um importante grau de liberdade para o problema de otimização, pois quando trabalhamos com um valor de pressão maior na planta de processamento de óleo, menos gasto de energia teremos no sistema de compressão para levar o gás produzido à pressão de exportação. Por outro lado, essa maior pressão no *topside* ocasiona uma maior contra-pressão no fundo do poço e a uma maior pressão no ponto de injeção do *gas-lift* para injetar a mesma vazão, ambos os efeitos ocasionam menor vazão de produção. Portanto, existe um ponto ótimo de pressão de *topside*.




Figura 4.51: Relação entre a pressão no topside com as variáveis de receita.




Figura 4.52: Relação entre a pressão no topside e as especificações de qualidade do processo.

A Figura 4.53 mostra os degraus inseridos nas variáveis de processo, vazão de injeção de *gas-lift* e pressão no *topside*. O objetivo desses testes é levantar dados para a etapa de identificação de modelos, possibilitando com isso correlacionar a vazão de produção de óleo com o *gas-lift* e a pressão de *topside*. Os gráficos mostram relações não lineares entre as variáveis do teste.

A Figura 4.54 mostra uma comparação entre a vazão de produção de óleo obtida através de o modelo proposto e os valores de planta, em diversos patamares de pressão de topside e variações de injeção de *gas-lift*. Os resultados mostram uma boa desempenho do modelo em descrever o estado-estacionário da planta para diferentes valores de pressão e *gas lift*.

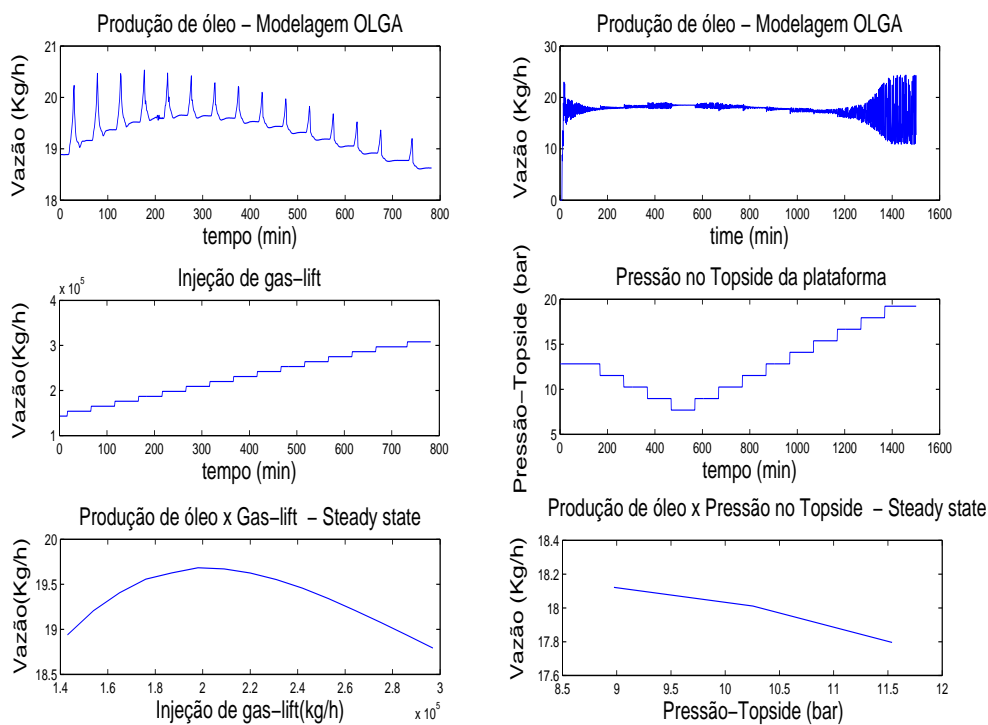


Figura 4.53: Etapa de identificação para determinação dos modelos de estado-estacionário.

As Figuras 4.55 a 4.57 mostram o comportamento do estado-estacionário da produção de óleo e gás, e do consumo de energia para variações na vazão de injeção de *gas lift* e de abertura da válvula *choke* de produção, em diferentes patamares de pressão. O perfil das curvas não muda para variações de pressão. A análise dessas variáveis é importante, pois elas compõem a função objetivo usada no problema de otimização. Os gráficos ilustram que existe uma relação não linear da vazão de óleo, de gás e do consumo de energia com a injeção de *gas lift*, e uma relação linear com a abertura da válvula *choke* e, também, linear com a pressão na planta de processamento da plataforma.




Figura 4.54: Comparação entre o modelo proposto e a planta.




Figura 4.55: Resultados do estado-estacionário para a produção de óleo.

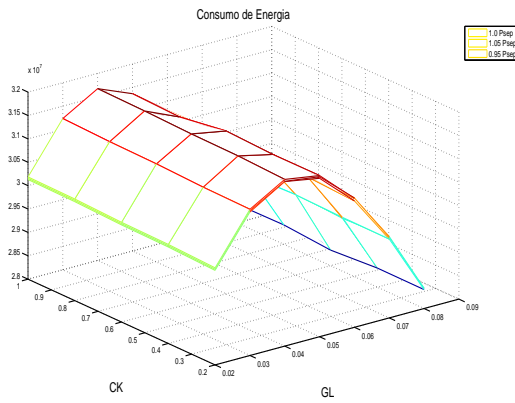


Figura 4.56: Resultados do estado-estacionário para o consumo de energia.




Figura 4.57: Resultados do estado-estacionário para a produção de gás.

A Figura 4.58 mostra uma comparação entre as variáveis, vazão de óleo, de gás e consumo de energia, que compõem a função econômica do problema de otimização, obtidas via modelo empírico identificado e os dados de planta. Esses resultados demonstram bom desempenho dos modelos não lineares em descrever o comportamento do estado-estacionário das variáveis econômicas para mudanças nos graus de liberdade do problema de otimização, injeção de *gas-lift* e pressão no *topside*. Sendo assim, a boa acurácia dos modelos não-lineares em descrever o estado-estacionario do processo permite usá-los como modelos para o problema de otimização, ao invés de usar os modelos fenomenológicos que descrevem o processo, reduzindo assim, o custo computacional para obtenção da solução ótima.




Figura 4.58: Comparação entre o modelo e a planta das principais variáveis que compõem o problema de otimização.

A Figura 4.59 mostra a estratégia NMPC integrada com a camada de otimização. Existem duas propostas de integração entre as camadas, são elas: Estratégia CL1 - São enviados da camada de otimização *setpoints* para as variáveis controladas; Estratégia CL2 - São enviados da camada de otimização alvos para as variáveis manipuladas e *setpoints* para as variáveis controladas. Os resultados permitem concluir que as duas estruturas conseguem mitigar os impactos da presença de golfadas, estabilizando o processo. Porém, a estratégia CL2, em que são enviadas as condições operacionais ótimas para as controladas e para as manipuladas, apresenta melhor desempenho em conduzir a planta para a condição operacional ótima do que a estratégia CL1, em que são enviados *setpoints* apenas para as variáveis controladas.

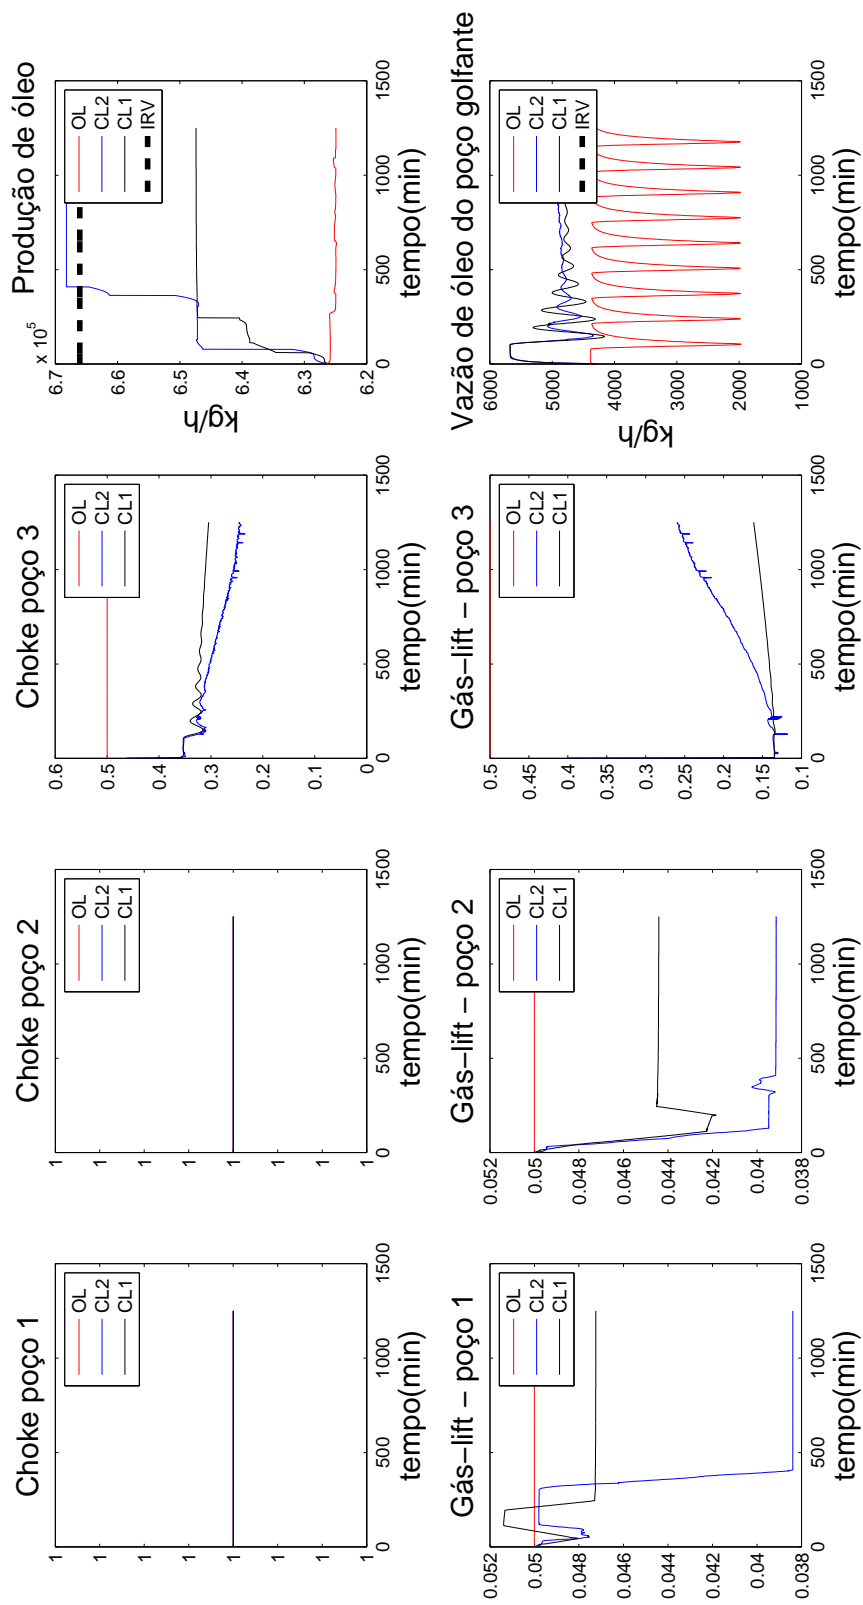


Figura 4.59: Resultados do NMPC integrado com a camada de otimização.

4.4.3 Considerações finais do caso III

Neste estudo de caso, conclui-se que a estratégia NMPC integrada com a camada de otimização consegue estabilizar a produção de óleo durante períodos de regime gol-fante, além de garantir as especificações de processo dentro dos limites operacionais. No que tange à otimização, o controlador conduz a planta até a condição operacional ótima determinada pela camada de otimização, sendo a estrutura com integração total, variáveis manipuladas e controladas, mais eficiente do que a estrutura em que há apenas integração nas variáveis controladas.

Capítulo 5

Conclusões

Neste trabalho foi proposta uma metodologia para aplicação de técnicas de controle preditivo acopladas com técnicas de otimização para processos de produção *offshore*. Neste contexto, foi traçado um planejamento para o trabalho, visando superar cada um dos desafios presentes para se alcançar esse objetivo. Portanto, organiza-se os resultados alcançados em cada etapa da seguinte forma:

- Aplicação da abordagem de controle e otimização em um estudo de caso *benchmark*

- Proposição de modelo não linear voltado para técnicas NMPC

O desempenho de estratégias de controle preditivo é determinada pela capacidade do modelo utilizado em descrever o comportamento da planta. Sendo assim, foi proposto neste trabalho uma metodologia de obtenção e identificação de modelos analíticos capazes de descrever processos com comportamentos não lineares. Os resultados desse estudo de caso mostraram que o modelo proposto consegue descrever de forma acurada o comportamento dos modelos fenomenológicos da planta, com baixa perda de desempenho do controlador quando comparado ao caso em que o controlador utiliza o modelo rigoroso, porém com significativa redução de custo computacional. Esse resultado abre um caminho promissor para aplicações industriais.

- Comparação da estratégia NMPC proposta com abordagem MPC adaptativa

Uma abordagem comum da literatura é resolver o problema não-linear (NLP) como um problema de programação quadrática (QP) em que a não linearidade do processo é descrita por um modelo linear adaptativo com os ganhos de processo determinados nas condições operacionais do início do ciclo de controle. A abordagem adaptativa tem a vantagem de

não precisar resolver um problema não linear, reduzindo o esforço computacional, porém durante a solução do problema de controle o ganho não é ajustado ao longo dos horizontes de controle e predição, o que pode degradar a solução devido ao erro de predição. Neste contexto, a abordagem NMPC proposta, em que um problema NLP é resolvido com o modelo analítico proposto, é comparada com a abordagem MPC adaptativa, mostrando-se bem mais eficaz do que a abordagem comum e com custo computacional similar. Portanto, esse resultado abre precedente para explorar a abordagem proposta em outras aplicações em que o MPC adaptativo foi aplicado, de forma a concluir assertivamente qual a abordagem mais eficiente.

– **Influência dos erros de modelagem e de perturbações não-medidas no desempenho do controlador proposto**

O resultados mostraram que a estratégia de NMPC proposta não perde desempenho para erros de dinâmica nos cenários estudados, porém o desempenho do controlador é bastante degradado para erros significativos de modelagem na determinação do estado-estacionário. Isso, deve-se ao fato de que a ação *feedback* calculada não consegue corrigir grandes desvios entre comportamentos não-lineares de planta e modelo. Com relação a perturbações não-medidas e, portanto, não modeladas, os resultados mostram que elas prejudicam em muito o desempenho do controlador quando têm forte relação com as variáveis controladas do escopo do controlador.

– **Desempenho do NMPC proposto com camadas de otimização**

A camada de NMPC proposta foi integrada com uma camada de otimização utilizando modelos rigorosos de estado-estacionário. Além disso, a solução do problema de otimização com a parte estática do modelo proposto foi comparada com a solução da otimização com modelos rigorosos. Ambos os casos mostraram bons resultados, no primeiro estudo o NMPC conduziu a planta para a condição ótima determinada pela camada de otimização, sem grandes dificuldades. No segundo estudo, as soluções do problema de otimização com modelo reduzido ou rigoroso foram próximas, não havendo degeneração da solução. Este resultado mostra que o modelo proposto consegue mapear adequadamente o estado-estacionário ao ponto de poder ser utilizado dentro de um problema de otimização sem impactos significativos na solução.

Outro cenário construído foi a integração entre o NMPC proposto com uma camada de otimização dinâmica (D-RTO). Os resultados desse caso mostram que o controlador consegue conduzir a planta através da tra-

jetória sugerida pelo D-RTO, sem apresentar desvios significativos, porém com menor esforço computacional. Este fato permite concluir que o problema de otimização econômica poderia ser resolvido junto com o problema de controle, transformando o NMPC proposto em um EMPC (*Economic Model Predictive Control*), sem a necessidade de haver duas camadas, de controle e de D-RTO, resultando em uma estrutura mais compacta, com menos parâmetros de sintonia, menos variáveis para analisar desempenho, e o principal, com menor custo computacional, pois não haveria necessidade de resolver o problema dinâmico com as equações fenomenológicas do processo.

- **Aplicação da abordagem de controle e otimização em uma planta industrial simulada de processamento de óleo *offshore***

Nesta seção, chega-se ao ponto principal da tese, que é a aplicação da metodologia desenvolvida no *benchmark*, em uma unidade de produção de óleo simulada. Um ponto de ressalva no que tange à construção da simulação foi a integração de dois ambientes de modelagem via comunicação OPC. Sendo, a modelagem do universo *subsea* realizada em *software* comercial de tradição na indústria de óleo e gás, OLGA, com o ambiente de modelagem, simulação e otimização (EMSO)(SOARES e SECCHI, 2003), em que toda a modelagem dos equipamentos no *topside* da plataforma foi construída, baseada em balanços de pressão para determinar os balanços de massa e energia do processo.

- **Proposição de modelo não linear voltado para processos de exploração e produção *offshore***

A metodologia desenvolvida no estudo de caso *benchmark* foi aplicada para descrever o comportamento das principais variáveis de processo de uma planta de produção de óleo *offshore*, que são: vazão de produção de óleo - rentabilidade do negócio, BSW - impacto nos custos com manutenção, de dutos e equipamentos de refino, devido à corrosão ocasionada pelo BSW; e TOG - impacto nos custos devido a multas aplicadas por órgão ambientais, caso a água descartada tenha teores elevados de óleo presente. Porém, a forte interação entre as variáveis operacionais e de processo dificultou a obtenção desses modelos de forma direta. Neste contexto, foi proposta uma estratégia de combinar os efeitos da vazão de produção de óleo com o BSW e o TOG vindo de cada um dos poços em variáveis auxiliares. Os resultados mostram uma boa acurácia do modelo proposto baseado em variáveis auxiliares para descrever o comportamento da planta, de forma a capacitá-lo para uso em estratégias de controle preditivo.

– **Desempenho da estratégia do NMPC proposto com modelos baseados em variáveis auxiliares para controlar uma planta de produção offshore**

Os resultados comprovaram que a estratégia do NMPC proposto consegue mitigar os impactos das golfadas na planta de processamento de óleo, conduzindo-a para os *setpoints* definidos e mantendo as especificações de processo, BSW e TOG, dentro dos limites operacionais. O NMPC proposto apresentou um desempenho bem superior ao de estratégias que utilizam modelos lineares obtidos nas regiões de contorno próximas à condição operacional do estudo de caso, em que não se conseguiu mitigar as golfadas e nem manter as especificações dentro dos limites.

Um ponto importante para frisar é o baixo custo computacional apresentado nesse estudo de caso, média de 10 segundos por ciclo de execução em um computador com 8GB de memória e processador i7, para resolver um problema NLP com 7 variáveis manipuladas, 3 variáveis controladas e uma variável distúrbio. Este resultado é muito interessante, pois abre frente para aplicações em escala industrial, em que o tempo computacional é fator determinante para o sucesso da aplicação.

– **Desempenho do NMPC proposto com camada de otimização para processos de produção offshore**

Neste estudo de caso é formulada uma camada de otimização econômica que engloba todo o processo, desde a produção vindo do poço até a exportação dos produtos, óleo e gás, além de considerar todas as opções de modo de operação com suas respectivas restrições. A pressão na planta de processamento da plataforma foi incorporada como grau de liberdade para o otimizador, pois ajusta o escoamento com os custos energéticos de compressão entre o ambiente submarino e o *topside* da plataforma. Por exemplo, pressões altas no separador gravitacional levam a contra-pressões no poço e com isso redução de produção, porém reduzem custos energéticos com a compressão e vice-versa. Os resultados desse exemplo mostraram que o NMPC conduz a planta para os *setpoints* determinados pela camada de otimização, mitigando as golfadas que perturbam o sistema e mantendo as restrições dentro de suas especificações. Portanto, esta contribuição é bastante relevante, pois apresenta a aplicação de duas estratégias de controle preditivo e de otimização integradas a todo o escopo de exploração e produção de óleo *offshore*.

Concluí-se que o trabalho fez importantes contribuições, nas áreas de aplicação de estratégias de controle preditivo não linear (NMPC), de integração de es-

estratégias de otimização com estratégias de controle preditivo, de aplicação de estratégias NMPC e otimização em processos de produção *offshore*, abrindo vertentes para trabalhos futuros.

- **Sugestões de trabalhos futuros**

- Aplicar a metodologia proposta em outros estudos de casos, explorando o potencial de redução de custo computacional para problemas de larga escala.
- Aplicar a metodologia proposta em estratégias ENMPC baseada na capacidade do modelo proposto em descrever a trajetória de otimização proposta pelo DRTO.
- Comparar a metodologia proposta com outras abordagens comuns da literatura, como por exemplo, multimodelos, linearizações locais ao longo da trajetória (LLT).
- Explorar a ausência de medições para obtenção de modelos não lineares em aplicações reais, propondo soluções baseadas em estimadores de estado.

Referências Bibliográficas

- AADALEESAN, P., MIGLAN, N., SHARMA, R., 2008, “Nonlinear System Identification Using Wiener Type Laguerre-Wavelet Network Model”, *Chemical Engineering Science*, v. 63, pp. 3932–3941.
- AGUIRRE, L. A., 2007, *Introdução à Identificação de Sistemas*. Editora UFMG.
- ALANGAR, A., DURAND, H., CHRISTOFIDES, P. D., 2015a, “On Identification of Well-Conditioned Nonlinear Systems: Application to Economic Model Predictive Control of Nonlinear Processes”, *AIChE*, v. 61, pp. 3353–3373.
- ALANGAR, A., ELLIS, M., CHRISTOFIDES, P. D., 2015b, “Economic Model Predictive Control of Nonlinear Process Systems Using Empirical Models”, *AIChE*, v. 61, pp. 816–830.
- ALMEIDA, E., SECCHI, A. R., 2012, “Solving Dynamic Optimization Infeasibility Problems”, *Computers and Chemical Engineering*, v. 36, pp. 227–246.
- BADGWELL, T. A., 1997, “A Robust Model Predictive Control Algorithm for Stable Nonlinear Plants”, *IFAC - Symposium on Advanced Control of Chemical Processes*, pp. 477–481.
- BELLMAN, R., 1957, “Dynamic Programming”, *Princeton University Press, Princeton, New Jersey, USA*.
- BENSON, H. Y., VANDERBEI, R. J., 1998, *Using LOQO to Solve Second-Order Cone Programming Problems*. Department of Operations Research and Financial Engineering, Princeton University, Princeton NJ.
- BEQUETTE, B. W., 1991, “Nonlinear Control of Chemical Processes - a review”, *Industrial Engineering Chemistry Research*, v. 30, pp. 1391–1413.
- BEQUETTE, B. W., GOPINATH, R. S., SISTU, P. B., 1993, “Computational Issues in Nonlinear Predictive Control”, *Computers Chemical Engineering*, v. 17, n. 4, pp. 361–366.

- BIEGLER, L. T., 2010, *Nonlinear Programming Concepts, Algorithms and Application to Chemical Processes*. SIAM, Philadelphia.
- BIEGLER, L. T., YANG, X., JASCHKE, J., 2014, “Fast Economic Model Predictive Control Based on NLP-sensitivities”, *Journal of Process Control*, v. 24, pp. 1260–1272.
- BIEGLER, L. T., YANG, X., FISCHER, G. A. G., 2015, “Advances in Sensitivity-based Nonlinear Model Predictive Control and Dynamic Real-time Optimization”, *Journal of Process Control*, v. 30, pp. 104–116.
- BLOEMEN, H. H. J., CHOU, C. T., BOOM, T. J. J., et al., 2001, “Wiener model identification and predictive control for dual composition control of a distillation”, *Journal of Process Control*, v. 11, pp. 601–620.
- BRENGEL, D. D., SEIDER, W. D., 1989, “Multistep Nonlinear Predictive Controller”, *Industrial Engineering Chemistry Research*, v. 28, pp. 1812–1822.
- BYRD, R. H., HRIBAR, M. E., NOCEDAL, J., 1999, “An Interior Point Algorithm for Large-Scale Nonlinear Programming”, *SIAM Journal on Optimization*, v. 9, n. 4, pp. 877–900.
- BYRD, R. H., NOCEDAL, J., WALTZ, R. A., 2006, *KNITRO: An Integrated Package for Nonlinear Optimization*. In: *Large-Scale Nonlinear Optimization*. [S.I.]: Springer.
- CAMACHO, E., BORDONS, C., 1998, *Model Predictive Control*. New York.
- CAMPOS, M. C. M. M., PEREZ, J. M. G. T., 2013, *Controle Avançado e Otimização na Indústria de Petróleo*. Editora Interciência.
- CERVANTES, A. L., AGAMENNONI, O. E., FIGUEROA, J. L., 2003a, “A Nonlinear Model Predictive Control Control System Based on Wiener Piecewise Linear Model”, *Journal of Process Control*, v. 13, pp. 665–666.
- CERVANTES, A., AGAMENNONI, O. E., FIGUEROA, J. L., 2003b, “A nonlinear model predictive control system based on Wiener piecewise linear models”, *Journal of Process Control*, v. 13, pp. 665–666.
- CHEN, H., ALLGOWER, F., 1997, “A Quasi-infinite Horizon Nonlinear Predictive Control Scheme for Stable Systems: Application to a CSTR”, *IFAC - Symposium on Advanced Control of Chemical Processes*, pp. 471–476.

- CHU, X., SEBORG, D. E., 2003, “Nonlinear Model Predictive Control Based on Hammerstein Models”. In: *Proceeding International Symposium on Process Systems Engineering*, p. 995.
- CLARKE, D., MOHTADI, C., TUFFS, P., 1987, “Generalized Predictive Control – Part II Extensions and Interpretations”, *Automatica*, v. 23, pp. 149–160.
- CUTLER, C. R., RAMAKER, B. L., 1980, “Dynamic Matrix Control - A Computer Control Algorithm”, *Proceedings Joint Automatic Control Conference*.
- DAEHLEN, J. S., EIKREM, G. O., JOHANSEN, T. A., 2003, “Nonlinear Model Predictive Control Using Trust-Region Derivative-Free Optimization”, *Journal of Process Control*, v. 24, pp. 1106–1120.
- DE VUSSE, J. G. V., 1964, “Plug-flow type reactor versus tank reactor”, *Chemical Engineering Science*, v. 19, pp. 994–997.
- DIEHL, M., BOCK, H. G., SCHLODER, J. P., 2005, “A Real-Time Iteration Scheme for Nonlinear Optimization in Optimal Feedback Control”, *SIAM Journal on Control and Optimization*, v. 43, pp. 1714–1736.
- DONES, I., MANENTI, F., PREISIG, H. A., 2010, “Nonlinear Model Predictive Control: Self-adaptative Approach”, *Industrial and Engineering Chemistry Research*, v. 49, pp. 4782–4791.
- DOWNS, J. J., VOGEL, E. F., 1993, “A plant-wide industrial process control problem”, *Computers chemical Engineering*, v. 17, pp. 245–255.
- DRUD, A. S., 1994, “CONOPT – A Large-Scale GRG Code”, *ORSA Journal on Computing*, v. 6, pp. 207–216.
- DURAIISKI, R. G., TRIERWEILER, J. O., SECCHI, A. R., 2001, “Nonlinear Model Predictive Control using Successive Linearization Approach”. In: *Proceedings of the 3rd Mercosur Congress on Process Systems Engineering (ENPROMER 2001)*, v. 1, pp. 301–306.
- EATON, A. N., BEAL, L. D. R., THORPE, S. D., 2017, “Real-Time Identification using Multi-fidelity Models in Managed Pressure Drilling”, *Computers and Chemical Engineering*, v. 97, pp. 76–84.
- EDELBAUM, T. N., 1962, “Theory of Maxima and Minima, in: Optimization Techniques with Applications to Aerospace Systems”, *G. Leitmann, Academic Press, New York*, pp. 1–32.

- EIKREM, G. O., 2006, “Stabilization of Gas-Lift Wells by Feedback Control”, *Ph.D dissertation, University of Science and Technology at Trondheim, Trondheim, Norway.*
- ELLIS, M., CHRISTOFIDES, P. D., 2015, “Real-Time Economic Model Predictive Control of Nonlinear Process Systems”, *AIChE*, v. 61, pp. 555–571.
- FOSS, B., AAMO, O., EIKREM, G., 2008, “On Instability in Gas Lift Wells and Schemes for Stabilization by Automatic Control”, *Society of Petroleum Engineers Production and Operation.*
- FRUZZETTI, K. P., PALAZOGLU, A., MCDONALD, K. A., 1997, “Nonlinear Model Predictive Control Using Hammerstein Models”, *Journal Process Control*, v. 7, pp. 31–41.
- FRUZZETTI, K. P., PALAZOGLU, A., MCDONALD, K. A., 2010, “Nonlinear Model Predictive Control Using Hammerstein Models”, *Journal of Process Control*, v. 7, n. 1, pp. 31–41.
- GARCIA, C. E., MORSHEDI, A. M., 1986, “Quadratic programming solution of dynamic matrix control (QDMC)”, *Chemical Engineering Communication*, v. 46, pp. 73–87.
- GARCIA, E. C., PRETT, M. D., MORARI, M., 1989, “Model Predictive Control: Theory and Practice – A survey”, *Automatica*, v. 25, pp. 335–348.
- GATTU, G., ZAFIRIOU, E., 1992, “Nonlinear Quadratic Dynamic Matrix Control with State Estimation”, *Industrial Engineering Chemistry Research*, v. 31, pp. 1096–1104.
- GEREVINI, G., FARENZENA, M., TRIERWEILER, J., 2018, “Slugging attenuation using Nonlinear Model Predictive Control in Offshore Oil Production”, *Journal of Petroleum Science and Engineering*, v. 165, pp. 187–198.
- GILL, P. E., MURRAY, W., WRIGHT, M. A. S. M. H., 1986, *User’s Guide for NPSOL (Version 4.0): A Fortran Package for Nonlinear Programming.* Stanford University systems optimization lab.
- GÓMEZ, J. C., JUTAN, A., BAEYENS, E., 2004, “Wiener model identification and predictive control of a pH neutralisation process”, *IEE Proceedings Part D: Control Theory and Applications*, v. 151, pp. 329–338.
- GODHAVN, J. M., FARD, M. P., FUCHS, P. H., 2005, “New slug control strategies, tuning rules and experimental results”, *Journal of Process Control*, v. 15, pp. 547–557.

- GOMES, J. C., JUTAN, A., BAEYENS, E., 2004, “Wiener Model Identification and Predictive Control of a pH Neutralisation Process”. In: *IEE Proceeding Part D: Control Theory and Applications*, v. 151, pp. 329–338.
- HANSEN, H., SKOGESTAD, S., JAHANSHAHI, E., 2012, “Control structure design for stabilizing unstable gas-lift oil wells”, *8th IFAC Symposium on Advanced Control of Chemical Processes, SI – Furama Riverfront*.
- HAYKIN, S., 1994, *Neural Networks – a Comprehensive Foundation*. London: McMillan.
- HAYKIN, S., 1996, *Adaptive Filterin Theory*. New Jersey: Prentice Hall.
- HENSON, M. A., 1998, “A Nonlinear Model Predictive Control: Control Status and Future Directions”, *Computers and Chemical Engineering*, v. 23, pp. 187–202.
- HENSON, M. A., SEBORG, D. E., 1997, *Model Predictive Control. Nonlinear Process Control*.
- HORN, R., 1994, *Topics in Matrix Analysis*. Cambridge University Press.
- HUAN, G. R., 1985, “A flash black oil model”, *Society of Petroleum Engineers*, pp. 947–952.
- HUANG, R., PATWARDHAN, S. C., BIEGLER, L. T., 2012, “Robust Stability of Nonlinear Model Predictive Control based on Extender Kalman Filter”, *Journal of Process Control*, v. 22, n. 1, pp. 82–89.
- INGA, J., MARQUARDT, W., 2016a, “Fast NMPC Scheme for Regulatory and Economic NMPC - A Review”, *Journal of Process Control*, v. 44, pp. 162–183.
- INGA, W. J., MARQUARDT, W., 2016b, “Fast NMPC schemes for regulatory and economic NMPC - A review”, *Journal of Process Control*, v. 44, pp. 162–183.
- JAHANSHAHI, E., 2013, *Control Solutions for Multiphase Flow Linear and Non-linear Approaches to Anti slug Control*. Tese de Doutorado, Norwegian University of Science and Technology.
- JAHANSHAHI, E., SKOGESTAD, S., 2015, “Anti slug control solutions based on identified model”, *Journal of Process Control*, v. 30, pp. 58–68.

- JAHANSHASHI, E., SKOGESTAD, S., 2017, “Nonlinear Control Solutions to Prevent Slugging Flow in Offshore Oil Production”, *Journal of Process Control*, v. 54, pp. 138–151.
- JASCHKE, J., YANG, X., BIEGLER, L. T., 2014, “Fast Economic Model Predictive Control Based on NLP-sensitivities”, *Journal of Process Control*, v. 24, pp. 1260–1272.
- KALMAN, R., 1960, “Contributions to the Theory of Optimal Control”, *Bulletin de La Societe Mathematique de Mexicana*, v. 5, pp. 102–119.
- KHANI, F., HAERI, M., 2015, “Robust Model Predictive Control of Nonlinear Processes represented by Wiener or Hammerstein Models”, *Chemical Engineering Science*, v. 129, pp. 223–231.
- KLATT, K. U., ENGELL, S., 1998, “Gain-Scheduling Trajectory Control of a Continuous Stirred Tank Reactor”, *Computers and Chemical Engineering*, v. 22, pp. 491–502.
- LAWRYNCZUK, M., 2010, “Computationally efficient nonlinear predictive control based on neural Wiener models”, *Neurocomputing*, v. 74, pp. 401–417.
- LAWRYNCZUK, M., 2007, “A Family of Model Predictive Control Algorithms with Artificial Neural Networks”, *International Journal of Applied Mathematics and Computer Science*, v. 17, pp. 217–232.
- LAWRYNCZUK, M., 2013, “Practical Nonlinear Predictive Control Algorithms for Neural Wiener Models”, *Journal of Process Control*, v. 23, pp. 696–714.
- LEE, G. H., RICKER, N. L., 1994, “Extend Kalman Filter Based Nonlinear Model Predictive Control”, *Industrial Engineering Chemistry Research*, v. 33, pp. 1530–1541.
- LI, W., BIEGLER, L. T., 1989, “Multistep, Newton-type Control Strategies for Constrained, Nonlinear Processes”, *Chemical Engineering Research and Design*, pp. 562–577.
- LONG, C. E., POLISETTY, P. K., GATZKE, E. P., 2006, “Nonlinear Model Predictive Control Using Deterministic Global Optimization”, *Journal of Process Control*, v. 16, pp. 635–643.
- LOPEZ-NEGRETE, R., BIEGLER, L. T., KUMAR, A., 2013, “Fast Nonlinear Model Predictive Control: Formulation and Industrial Process Applications”, *Computers and Chemical Engineering*, v. 51, pp. 55–64.

- MANENTI, F., 2011, “Considerations on Nonlinear Model Predictive Control Techniques”, *Computers and Chemical Engineering*, v. 35, pp. 2491–2509.
- MANER, B. R., DOYLE, F. J., 1997, “Polymerization Reactor Using Autoregressive-plus Volterra-based MPC”, *AIChE Journal*, v. 43, pp. 1763–1784.
- MANER, B. R., DOYLE, F. J., OGUNNAIKE, B. A., et al., 1997, “Nonlinear Model Predictive Control of a Simulated Multivariable Polymerization Reactor Using Second-Order Volterra Models”, *Automatica*, v. 32, pp. 1285–1301.
- MARINO, R., TOMEI, P., 1993, “Global Adaptive Output-Feedback Control of Nonlinear Systems: Part II: Nonlinear Parametrization”, *Automatic Control*, v. 38, pp. 33–48.
- MARLIN, E. T., FORBES, J. F., 1995, “Selecting the proper location for economic optimization multivariable control or RTO”, *In: NPRA Computer Conference, National Petroleum Refiners Association*, pp. 95–125.
- MARTI, R., LUCIA, S., SARABIA, D., 2015a, “An efficient distributed algorithm for multi-stage robust nonlinear predictive control”, *In: Proc. of the European control conference*.
- MARTI, R., LUCIA, S., SARABIA, D., 2015b, “Improving Scenario Decomposition Algorithms for Robust Nonlinear Model Predictive Control”, *Computers and Chemical Engineering*, v. 79, pp. 30–45.
- MAYNE, D. Q., 1997, “Nonlinear Model Predictive Control: an Assessment”, *Chemical Process Control*, pp. 217–231.
- MAYNE, D. Q., MICHALSKA, H., 1990, “Receding Horizon Control of Nonlinear Systems”, *IEEE – Transaction Automatic Control*, v. 35, pp. 814–824.
- MAYNE, D. Q., MICHALSKA, H., 1991b, “Receding Horizon Control of Constrained Nonlinear Systems”, *European Control Conference*, pp. 2037–2042.
- MAYNE, D. Q., MICHALSKA, H., 1991c, “Robust Receding Horizon Control”, *IEEE – Conference on Decision and Control*, pp. 64–69.
- MEGLIO, F., 2011, *Dynamics and Control of Slugging in Oil Production*. Tese de Doutorado, Paris Institute of Technology.

- MIGLAN, N., SAHA, P., SHARMA, R., et al., 2008, “Nonlinear system identification using Wiener type Laguerre–Wavelet network model”, *Chemical Engineering Science*, v. 15, pp. 3932–3941.
- MIYOSHI, S. C., NUNES, M., SALLES, A., et al., 2018, “Nonlinear Model Predictive Control Application for Gas-lift based Oil Production”. In: *Proceeding of the 28th European Symposium on Computer Aided Process Engineering*, v. 43, pp. 1177–1182.
- NICOLAO, G. D., MAGNI, L., SCATTOLINI, R., 1996, “On the Robustness of Receding-horizon Control with Terminal Constraints”, *IEEE – Transaction Automatic Control*, v. 41, pp. 451–453.
- NORQUAY, S. J., PALAZOGLU, A., ROMAGNOLI, J. A., 1999, “Application of Wiener Model Predictive Control (WMPC) to an Industrial C2-Splitter”, *Journal of Process Control*, v. 9, pp. 461–473.
- PEARSON, R. K., OGUNNAIKE, B. A., 1997, “Nonlinear Process Identification”, *Nonlinear Process Control*, pp. 11–110.
- PENG, J., DUBAY, R., HERNANDEZ, J. M., et al., 2011, “A Wiener neural network-based identification and adaptive Generalized Predictive Control for nonlinear SISO systems”, *Industrial and Engineering Chemistry Research*, v. 50, pp. 7388–7397.
- PEREZ, J., 2006. “Controle Preditivo Robusto com Realimentação de Saída”. .
- PETERSON, T., HERNANDEZ, E., ARKUN, Y., et al., 1992, “A Nonlinear DMC Algorithm and Its Application to a Semibatch Polymerization Reactor”, *Chemical Engineering Science*, v. 47, pp. 737–753.
- PIRNAY, H., LOPEZ-NEGRETE, R., BIEGLER, L. T., 2012, “Optimal Sensitivity based on IPOPT”, *Mathematical Programn Computer*, v. 4, pp. 307–331.
- PLUCENIO, A., 2010, “Desenvolvimento de Técnicas de Controle Não linear para Elevação de Fluidos Multifásicos”, *Tese de D.sc., UFSC, Florianópolis, SC, Brasil*.
- PONTRYAGIN, L. S., BOLTYANSKII, V. G., GAMKRELIDZE, R. V., 1962, “The Mathematical Theory of Optimal Processes”, *John Wiley and Sons, USA*, pp. 1–32.

- POTTMANN, M., SEBORG, D. E., 1997, “A Nonlinear Predictive Control Strategy Based on Radial Basis Function Models”, *Computers and Chemical Engineering*, v. 21, pp. 965–980.
- POWELL, P. J., 1978a, “Design and Testing of a Generalized Reduced Gradient Code for Nonlinear Programming”, *ACM Transactions on Mathematical Software (TOMS)*, v. 4, pp. 34–50.
- POWELL, P. J., 1978b, “A Fast Algorithm for Nonlinearly Constrained Optimization Calculations”, *Numerical Analysis*, pp. 144–157.
- PROPOI, A., 1963, “Use of Linear Programming Methods for Synthesizing Sampled-data Automatic Systems”, *Automatic Remote Control*, v. 24, pp. 837–844.
- RASHID, M., MHASKAR, P., SWARTZ, C. L. E., 2016, “Multi-rate modeling and economic model predictive control of the electric arc furnace”, *Journal of Process Control*, v. 40, pp. 50–61.
- RAWLINGS, B. J., MUSKE, K., 1993, “The Stability of Constrained multivariable Receding Horizon Control”, *IEEE Transactions on Automatic Control*, v. 38, pp. 1512–1516.
- RIBEIRO, C. H. P., 2012, “Controle Preditivo Multivariável em Plataformas para a Produção de Petróleo com Restrição de Qualidade”, *Dissertação de M.sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil*.
- RIBEIRO, C., MIYOSHI, S., SECCHI, A., et al., 2016, “Model Predictive Control with Quality Requirements on Petroleum Production Platforms”, *Journal of Petroleum Science and Engineering*, v. 137, pp. 10–21.
- RIBEIRO, L. D., SECCHI, A. R., 2018, “A methodology to obtain analytical models that reduces the computational complexity faced in real time implementation of NMPC controllers”, *Brazilian Journal of Chemical Engineering*.
- RICHALET, J., RAULT, A., TESTUD, J., et al., 1978, “Model Predictive Heuristic Control: Applications to Industrial Processes”, *Automatica*, v. 43, pp. 413–418.
- RODRIGUES, M., ODLOAK, D., 2003, “An Infinite Horizon Model Predictive Control for Stable and Integrating Processes”, *Computers and Chemical Engineering*, v. 27, pp. 1113–1128.

- SALAHSHOOR, K., ZAKERI, S., SEFAT, M. H., 2013a, “Stabilization of gas-lift oil wells by a nonlinear model predictive control scheme based on adaptive neural network models”, *Engineering Applications of Artificial Intelligence*, v. 26, pp. 1902–1910.
- SALAHSHOOR, K., ZAKERI, S., SEFAT, S., 2013b, “Stabilization of Gas-lift Oil Wells by a Nonlinear Model Predictive Control Scheme Based on Adaptive Neural Network Models”, *Engineering Applications of Artificial Intelligence*, v. 26, pp. 1902–1910.
- SANTOS, L. S., 2013, “Otimização Dinâmica Usando Aproximação com Base Wavelets Adaptativa”, *Tese de D.sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil*.
- SCHITTKOWSKI, K., 1985, “NLPQ: A Fortran- Subroutine Solving Constrained Nonlinear Programming Problems”, *Annals of Operations Research*, v. 5, pp. 485–500.
- SEBORG, D. E., MELLICHAMP, D. A., EDGAR, T. F., et al., 2010, *Process Dynamics and Control*. John Wiley and Sons. Inc.
- SEYAB, R. K. A., CAO, Y., 2006, “Nonlinear model predictive control for the ALSTOM gasifier”, *Journal of Process Control*, v. 16, pp. 795–808.
- SHAO, W., BOIKO, I., AL-DURRA, A., 2016, “Control oriented modeling of gas-lift system and analysis of casing heading instability”, *Journal of Natural Gas Science and Engineering*, v. 29, pp. 365–381.
- SKOFTELAND, G., GODHAVN, J. M., 2003a, “Suppression of Slugs in Multiphase Flow Lines by Active Use of Topside Choke – Field Experience and Experimental Results”, *11th BHR Group Multiphase Production International Conference, San Remo, Italy*, pp. 527–542.
- SKOFTELAND, G., GODHAVN, J. M., 2003b, “A Low-dimensional Dynamic Model of Severe Slugging for Control Design and Analysis”, *11th BHR Group Multiphase Production International Conference, San Remo, Italy*, pp. 117–133.
- SOARES, R. P., SECCHI, A. R., 2003, “A new environment for modelling, simulation and optimization”, *Computer Aided Chemical Engineering*, v. 14, pp. 947–952.
- SPELLUCCI, P., 2002, “DONLP2 users guide”, *TU Darmstadt, [S.I.]*, pp. 144–157.

- SRINIWAS, G. R., ARKUN, Y., 1997, “A Global Solution to the Nonlinear Predictive Control Algorithms Using Polynomial ARX models”, *Computers and Chemical Engineering*, v. 21, pp. 431–439.
- STAMNES, O. N., ZHOU, J., AAMO, O. M., 2008, “Adaptive Observer Design for the Bottomhole Pressure of a Managed Pressure Drilling System”. In: *IEEE Conference on Decision and Control*.
- STORKAAS, E., SKOGESTAD, S., 2002, “Stabilization of Severe Slugging Based on Low-dimensional Nonlinear Model”, *AIChE Annual meeting, Paper 259e, Indianapolis, USA*.
- SU, H. T., MCAVOY, T. J., 1997, *Artificial Neural Networks for Nonlinear Process Identification and Control*.
- SUWARTADI, E., KRISHNAMOORTHY, D., JASCHKE, J., 2018, “Fast Economic Model Predictive Control for a gas lifted Well Network”, *International Federation of Automatic Control*, v. 51, pp. 25–30.
- TATJEWSKI, P., 2007, *Advanced Control of Industrial Process, Structure and Algorithms*. Springer.
- TEXEIRA, A. F., 2013, “Otimização da Produção de Poços de Petróleo que Operam com Gás Lift Contínuo”, *Dissertação de M.sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil*.
- THOMAZ, D. M., 2017, “Estratégia de Controle Preditivo Multivariável para um Sistema de Compressão de Gás de Plataforma do Pré-sal”, *Dissertação de M.sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil*.
- TRIERWEILER, J. O., SECCHI, A. R., 2000, “Exploring the Potentiality of using Multiple Model Approach in Nonlinear Model Predictive Control”. In: Allgöwer, F., Zhen, A. (Eds.), *Nonlinear Model Predictive Control*, v. 26, Birkhäuser Verlag, pp. 191–203.
- VALLERIO, M., IMPE, J. V., LOGIST, F., 2014, “Tuning of NMPC Controllers Via Multi-objective Optimization”, *Computers and Chemical Engineering*, v. 61, pp. 38–50.
- VOLCKER, C., JORGENSEN, J. B., THOMSEN, P. G., 2011, “NMPC for Oil Reservoir Production Optimization”, *21st European Symposium on Computer Aided Process Engineering – ESCAPE 21*.
- WAECHTER, A., CARL, L., 2014, “Introduction to IPOPT. A Tutorial for Downloading, Installing, and Using IPOPT”, *COIN-OR. [S.I.]*, p. Rev. 2474.

- WANG, X., MAHALEC, V., QIAN, F., 2017, “Globally optimal dynamic real time optimization without model mismatch between optimization and control layer”, *Computers and Chemical Engineering*, v. 104, pp. 64–75.
- WIENER, N., 1989, “Nonparametric Identification of Hammerstein Systems”, *IEEE-Transactions on Information Theory*, v. 35, n. 2, pp. 409–418.
- WILLERSRUD, A., IMSLAND, L., 2013, “Short-term Production Optimization of Offshore Oil and Gas Production Using Nonlinear Model Predictive Control”, *Journal of Process Control*, v. 23, pp. 215–223.
- YANG, X., BIEGLER, L. T., 2013, “Advanced-Multi-Step Nonlinear Model Predictive Control”, *Journal Process Control*, v. 23, pp. 1116–1128.
- YING, C. M., JOSEPH, B., 1999, “Performance and Stability Analysis of LP-MPC and QP-MPC Cascade Control Systems”, *AIChE Journal*, pp. 1521–1534.
- ZANIN, A. C., 2001. “Implementação Industrial de um Otimizador em Tempo Real” . .
- ZANIN, A. C., GOUVÊA, M. T. D., ODLOAK, D., 2000, “Industrial Implementation of a Real-Time Optimization Strategy for Maximizing Production of LPG in a FCC Unit”, *Computers and Chemical Engineering*, v. 24, pp. 525–531.
- ZAVALA, V. M., BIEGLER, L. T., 2009, “Optimization-Based Strategies for the Operation of Low-Density Polyethylene Tubular Reactors: Nonlinear Model Predictive Control”, *Computers and Chemical Engineering*, v. 33, pp. 1735–1746.
- ZHENG, A., 1997, “A Computationally Efficient Nonlinear MPC Algorithm”, *Process American Control Conference*, pp. 1623–1627.

Apêndice A

Desenvolvimento do modelo em estado-estacionário

Figura A.1 mostra a relação entre as variáveis manipuladas e as variáveis de perturbação com as variáveis controladas, ilustrando como o modelo multiparamétrico foi construído para representar as condições de estado-estacionário. O procedimento usado para obter o modelo multi-paramétrico foi : (1) Todas as variáveis de perturbação são mantidas constantes e degraus são inseridos nas variáveis manipuladas. Desta forma, é possível obter uma função polinomial que descreve a relação entre as variáveis manipuladas e as variáveis controladas; (2) Nesta etapa é inserida uma sequência de degraus nas variáveis de perturbação e em cada etapa dessa sequência é repetida a etapa 1, gerando um perfil dos parâmetros, da função polinomial da etapa 1, em função das perturbações; (3) Nesta última etapa, há uma massa de dados dos parâmetros da função polinomial da etapa 1 correlacionados com as perturbações, possibilitando assim, obter uma função polinomial que relaciona cada parâmetro com as perturbações.




Figura A.1: Representação do modelo multi-paramétrico para descrever as condições de estado-estacionário.

Apêndice B

Desenvolvimento do modelo dinâmico

Considerando que um modelo linear pode descrever o comportamento dinâmico e um modelo não linear pode descrever o estado-estacionário, é possível representar o processo por uma estrutura baseada nos modelos de Hammerstein, como mostra a Figura B.1.




Figura B.1: Modelo Hammerstein

Neste contexto, um modelo de segunda ordem foi escolhido para representar as dinâmicas dos processos presentes nos estudos de caso desse trabalho, porém, essa estrutura é capaz de descrever diversos processos da engenharia química. O comportamento não-linear do estado-estacionário é representado pela Equação B.1, onde $\bar{v}(\underline{u})$ são as entradas do modelo.

Equação B.1 mostra a dinâmica de um sistema linear representada por um modelo de segunda ordem:

$$\tau^2 \frac{d^2 \bar{y}}{dt} + 2 \varepsilon \tau \frac{d \bar{y}}{dt} + \bar{y} = \bar{v} \quad (\text{B.1})$$

Onde

$$\begin{aligned} \bar{y}(t) &= y(t) - y(0) \\ \bar{v}(\underline{u}) &= y^{ss}(\underline{u}) - y(0) \end{aligned}$$

Aplicando a transformada de Laplace na Equação B.1, considerando \underline{u} constante:

$$\bar{Y}(s) = \frac{y^{ss}(\underline{u}) - y(0)}{s(\tau^2 s^2 + 2\varepsilon\tau s + 1)}$$

e no domínio do tempo:

$$y(t) = y(0) + (y^{ss}(\underline{u}) - y(0)) \left(1 - \frac{\tau_1 \exp\left(-\frac{t}{\tau_1}\right) - \tau_2 \exp\left(-\frac{t}{\tau_2}\right)}{\tau_1 - \tau_2} \right) \quad (\text{B.2})$$

onde

$$\tau_1 = \frac{\tau}{\varepsilon - \sqrt{\varepsilon^2 - 1}} \quad (\text{B.3})$$

$$\tau_2 = \frac{\tau}{\varepsilon + \sqrt{\varepsilon^2 - 1}} \quad (\text{B.4})$$

Substituindo as Equações B.3 e B.4 na Equação B.2 e assumindo que existe tempo morto, t_d , teremos:

$$\underline{y}(t) = \underline{y}^0 + [\underline{y}^{ss}(\underline{u}, \underline{d}) - \underline{y}^0] \underline{f}(t) \quad (\text{B.5})$$

onde

$$\underline{f}(t) = 1 - \exp\left(\frac{-\varepsilon(t - t_d)}{\tau}\right) \left[\cosh\left(\frac{\sqrt{\varepsilon^2 - 1}}{\tau}(t - t_d)\right) + \frac{\varepsilon}{\sqrt{\varepsilon^2 - 1}} \sinh\left(\frac{\sqrt{\varepsilon^2 - 1}}{\tau}(t - t_d)\right) \right] \quad (\text{B.6})$$

Equação B.6 pode descrever um sistema de primeira ordem quando $\varepsilon \rightarrow 1$, $\tau \gg 1$ e $t_d = 0$. Substituindo esses valores nos parâmetros e reescrevendo a Equação B.6, resultando na Equação B.9.

Equação B.7 mostra a dinâmica de um sistema linear representado por um modelo de primeira ordem (ODE - Equação Diferencial Ordinária) :

$$\tau \frac{d\bar{y}}{dt} + \bar{y} = \bar{v} \quad (\text{B.7})$$

onde

$$\begin{aligned}\bar{y}(t) &= y(t) - y(0) \\ \bar{v}(\underline{u}) &= y^{ss}(\underline{u}) - y(0)\end{aligned}$$

Aplicando a transformada de Laplace na Equação B.7, considerando \underline{u} constante:

$$\bar{Y}(s) = \frac{y^{ss}(\underline{u}) - y(0)}{s(\tau s + 1)}$$

e no domínio do tempo:

$$\begin{aligned}y(t) &= y(0) + (y^{ss}(\underline{u}) - y(0)) \left[1 - \exp\left(-\frac{t}{\tau}\right) \right] \\ y(t) &= y(0) + (y^{ss}(\underline{u}) - y(0)) f(t)\end{aligned}\tag{B.8}$$

onde, a função temporal obtida através de um modelo de primeira ordem para descrever o comportamento dinâmico do sistema é dada pela equação abaixo:

$$f(t) = 1 - \exp\left(-\frac{t}{\tau}\right)\tag{B.9}$$

Sendo assim, é possível descrever diversos processos com a estrutura ilustrada pela Equação 3.6, onde y^{ss} representa o estado-estacionário e $f(t)$ descreve a dinâmica. Essas funções são obtidas com aplicações degraus nas variáveis manipuladas. Para os estudos de caso presentes nesse trabalho, as Equações 3.7 e 3.8 descrevem o estado-estacionário e a Equação 3.9 descreve o comportamento dinâmico.

Figura B.2 mostra as dinâmicas que o modelo proposto pode descrever. Por exemplo, sistemas de segunda ordem com ou sem tempo morto, subamortecido ou superamortecido, e sistemas de primeira ordem. Portanto, é possível descrever o comportamento dinâmico dos estudos de caso presentes e de sistemas dinâmicos similares. A estimação de parâmetros da estrutura dinâmica do modelo proposto consiste na solução da minimização da soma das diferenças entre a resposta da planta e a do modelo proposto, Equação B.10. A performance do modelo proposto com os parâmetros estimados através da minimização da Equação B.10 foi bem-sucedida para os estudos de caso.

$$\min_{\underline{\theta}} \sum_{k=0}^n (\hat{y}(\underline{u}(t_k), \underline{d}(t_k), \underline{\theta}) - y(\underline{u}(t_k), \underline{d}(t_k), \underline{\theta}))^2\tag{B.10}$$

onde $\hat{y} \in \Re^{n_y}$ representa o comportamento do processo, $y \in \Re^{n_y}$ representa o modelo

proposto, $\underline{u}(t_k) \in \mathfrak{R}^{n_u}$ e $\underline{d}(t_k) \in \mathfrak{R}^{n_d}$ são os sinais das controladas e das perturbações, respectivamente, e $\underline{\theta} = [\zeta, \tau, \tau_d]$ são os parâmetros estimados do modelo dinâmico.




Figura B.2: Modelo proposto para descrever as dinâmicas do processo.

Apêndice C

Definição do produto de Hadamard HORN (1994)

Sendo A e B matrizes $m \times n$, o produto de Hadamard é a matriz $A \otimes B$ de mesma dimensão que as matrizes A e B , com elementos dado pela Equação C.1.

$$(A \otimes B)_{i,j} = (A)_{i,j}(B)_{i,j}, \text{ para todo } 1 \leq i \leq m \text{ and } 1 \leq j \leq n \quad (\text{C.1})$$

Se a matriz A tem dimensão $m \times n$ e a matriz B tem dimensão $p \times q$, onde $m \neq p$ ou $n \neq q$, o produto de Hadamard não existe.