



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO (CTC)  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE AUTOMAÇÃO E SISTEMAS

JOSÉ DOLORES VERGARA DIETRICH

**CONTRIBUIÇÕES AO CONTROLE PREDITIVO E OTIMIZAÇÃO COM  
APLICAÇÃO EM ENERGIAS RENOVÁVEIS**

Florianópolis  
2020

JOSÉ DOLORES VERGARA DIETRICH

**CONTRIBUIÇÕES AO CONTROLE PREDITIVO E OTIMIZAÇÃO COM  
APLICAÇÃO EM ENERGIAS RENOVÁVEIS**

Tese submetida ao Programa de Pós-Graduação em Engenharia de Automação e Sistemas da Universidade Federal de Santa Catarina para a obtenção do título de doutor em Engenharia de Automação e Sistemas.  
Orientador: Prof. Julio Elias Normey Rico, Dr.  
Coorientador: Prof. Antonio Ferramosca, Dr. (CONICET)  
Prof. Marcus Vinicius Americano da Costa Filho, Dr. (UFBA)

Florianópolis  
2020

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Vergara-Dietrich, José Dolores

Contribuições ao controle preditivo e otimização com aplicação em energias renováveis / José Dolores Vergara Dietrich ; orientador, Julio Elias Normey-Rico, coorientador, Antonio Ferramosca, coorientador, Marcus Vinicius Americano da Costa Filho, 2020.

183 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia de Automação e Sistemas, Florianópolis, 2020.

Inclui referências.

1. Engenharia de Automação e Sistemas. 2. Controle Preditivo. 3. Real Time Optimization. 4. Offset-Free. 5. Energia Renovável. I. Normey-Rico, Julio Elias. II. Ferramosca, Antonio. III. Costa Filho, Marcus Vinicius Americano da IV. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia de Automação e Sistemas. V. Título.

JOSÉ DOLORES VERGARA DIETRICH

**CONTRIBUIÇÕES AO CONTROLE PREDITIVO E OTIMIZAÇÃO COM  
APLICAÇÃO EM ENERGIAS RENOVÁVEIS**

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Jorge Otávio Trierweiler, Dr.  
Universidade Federal do Rio Grande do Sul

Prof. Carlos Bordons Alba, Dr.  
Universidad de Sevilla

Prof. Daniel Ferreira Coutinho, Dr.  
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutor em Engenharia de Automação e Sistemas.

---

Prof. Werner Kraus Jr., Dr.  
Coordenador do Programa de Pós-Graduação

---

Prof. Julio Elias Normey Rico, Dr.  
Orientador

Florianópolis, 2020.

Dedico este trabalho aos meus pais, Izabel e José (*in  
memorian*), fontes inesgotáveis de inspiração.

## AGRADECIMENTOS

Agradeço, primeiramente, ao meu orientador, prof. Julio Normey, pela sua paciência e amizade que me permitiram trilhar os caminhos do doutorado de uma forma mais prazerosa. Aprendi muito com a sua forma de lidar com os problemas, sempre com calma sem perder a energia.

Agradeço aos meus co-orientadores Antonio Ferramosca e Marcus Americano que, sem eles, não teria chegado onde cheguei. Muito obrigado pelos ensinamentos.

Agradeço ao prof. Carlos Bordons e à sua esposa Ana, pela amizade e parceria. Obrigado pela recepção em Sevilla, cidade pela qual me apaixonei. Pessoas como vocês marcam nossas vidas de forma indelével.

Agradecimento especial ao prof. Daniel Limón (Universidad de Sevilla) que, mesmo sem ter tempo para me receber, estendeu-me a mão e me ensinou com paciência e maestria as sutilezas da teoria de estabilidade do MPC, fundamentais para o meu trabalho. Agradeço de coração.

Não posso deixar de agradecer ao meu grande amigo Paulo Mendes (pós-doutorando do PPGEAS), que me auxiliou desde o começo com o tema do MPC. Sua ajuda foi inestimável, tchê. Obrigado ao nosso companheiro de discussões e de trabalho, o sempre alerta Marecelo Menezes (doutorando), destaque do grupo que nos inspira com tanta energia para o estudo. Obrigado, também, ao meu colega de bancada Diogo Ortiz Machado (outro tchê doutorando) pelas muitas conversas e por mostrar-me sempre um ponto diferente que não teria visto sem sua ajuda.

Obrigado aos colegas do Grupo de Pesquisa GPER por cada colaboração, por cada congresso juntos e pelas reuniões, sempre produtivas.

Por último sem ser menos importante, agradeço à minha família: à minha mãe Izabel pela vida, pelo amor, apoio e dedicações incondicionais além das orações inesgotáveis; ao meu pai José (*in memoriam*) pela inspiração e dedicação com que me ensinou, desde pequeno e com muita paciência, o que é a engenharia; aos meus irmãos Taiana, Miriam, Leonardo e Aline pela torcida e carinho de sempre; à minha querida esposa Tatiana, pelo amor, paciência e companheirismo dioturnos. Esta vitória é certamente tua, também. Como sabemos, sem você esta aventura não aconteceria; aos meus filhos Gabriela e Eduardo pelo amor e pela paciência. Obrigado por renovarem em mim a alegria e a esperança todos os dias.

Obrigado a Deus pelo sopro de vida e pelas oportunidades vividas.

*“Há três caminhos para o fracasso:  
não ensinar o que se sabe, não praticar o  
que se ensina, não perguntar o que se ignora.”  
( São Beda, 720 d.C.)*

## RESUMO

Sistemas eficientes, sustentáveis e diversificados de geração de energia elétrica são uma preocupação crescente na maioria dos países. Tais sistemas enfrentam dificuldades recorrentes de confiabilidade e qualidade da energia devido à característica estocástica da maioria das fontes renováveis. Esses problemas podem ser minimizados dependendo da estratégia de controle utilizada. De forma geral, uma das técnicas de controle avançado mais utilizadas é o chamado controle preditivo (MPC), devido a sua característica de combinar a otimização econômica e o atendimento às restrições do processo. A maioria dos trabalhos publicados na área concentram-se em técnicas determinísticas e, apesar de que métodos estocásticos têm apresentando resultados promissores, várias propostas de MPC robusto e estocástico são provavelmente muito complexas para a implementação nas indústrias de processos, onde normalmente, incentiva-se o desenvolvimento de alternativas mais simples. Além disso, o MPC pode ter dificuldades para encontrar o ponto ótimo do sistema real, já que o controlador preditivo é baseado em um modelo aproximado do sistema. Assim, esta tese apresenta contribuições ao controle avançado de plantas de geração de energia renovável com base em estratégias de controle preditivo, incluindo formulações estocásticas. Entre elas se destacam: a avaliação da topologia na eficiência de campos solares de grande porte, a incorporação de técnicas probabilísticas na formulação do MPC frente a estocasticidade presente na geração renovável e a avaliação de técnicas probabilísticas em sistemas com diversas fontes de geração renovável, além de apresentar casos de estudo de usinas de cana-de-açúcar como fornecedoras de energia elétrica para a rede externa. Outro objetivo alcançado nesta tese é projetar um controlador MPC que possa, através das medidas da planta real, compensar eventuais efeitos não modelados do sistema para que o controlador possa convergir à solução ótima com garantia de estabilidade, permitindo enfrentar os problemas da estocasticidade das fontes de geração renovável. Como resultado disso, apresenta-se um controlador *Offset-Free* (sem erro de offset) chamado de Controlador Preditivo Econômico de uma Camada que combina as vantagens do MPC com a estratégia de Adaptação via Modificadores (MA), permitindo controlar o sistema levando-o para o ponto ótimo da planta real. Todos os estudos realizados foram validados com experimentos em simulação, a maioria deles com dados de plantas reais. Em suma, as contribuições desta tese podem ser classificadas em três categorias: a) Contribuições para a *modelagem de sistemas híbridos* (com diversas fontes de energia) de geração renovável, incluindo estruturas hierárquicas, cujos resultados oferecem recursos de como modelar diversas situações reais em sistemas renováveis; b) *Análise* do uso das restrições probabilísticas (CC) em sistemas de geração renovável, seu conceito e estruturação em sistemas multivariáveis e seus efeitos, tanto benéficos quanto nocivos, para o sistema; e c) *Proposta de um controlador Offset-Free* que permite lidar com eventuais dinâmicas não modeladas em estruturas de controle hierárquico, o que permite que o controlador encontre o ponto de operação ótimo da planta real e não apenas do modelo utilizado pelo controlador.

**Palavras-chave:** Controle Preditivo. Real Time Optimization. Offset-Free. Energia Renovável.



## ABSTRACT

Efficient, sustainable and diversified power generation systems are a growing concern in most countries. Such systems face recurrent difficulties of reliability and power quality due to the stochastic characteristics of most renewable sources. These problems can be minimized depending on the control strategy used. In general, one of the most commonly used advanced control techniques is the so-called Model Predictive Control (MPC), due to its characteristic of combining economic optimization and meeting process constraints. Most of the studies published in this area focus on deterministic techniques and, despite the fact that stochastic methods have presented promising results, several proposals of robust and stochastic MPC are probably very complex for the implementation in process industries, where normally, the development of simpler alternatives is encouraged. In addition, the MPC may have difficulties to find the optimum point of the real system, since the predictive controller is based on an approximate model of the system. Thus, this thesis presents contributions to the advanced control of renewable energy generation plants based on predictive control strategies, including stochastic formulations. Among them are: the evaluation of the topology in the efficiency of large solar fields, the incorporation of probabilistic techniques in the formulation of MPC against stochasticity present in renewable generation and the evaluation of probabilistic techniques in systems with various sources of renewable generation, in addition to presenting case studies of sugarcane plants as suppliers of electricity to the external grid. Another objective achieved in this thesis is to design an MPC controller that can, through the measurements of the actual plant, compensate for eventual unmodelled effects of the system so that the controller can converge to the optimum solution with a guarantee of stability, allowing to face the problems of stochasticity of renewable generation sources. As a result, an Offset-Free controller called One-Layer Economic Model Predictive Controller is presented that combines the advantages of MPC with the Modifier Adaptation (MA) strategy, allowing to control the system taking it to the optimum point of the real plant. All the studies performed have been validated with simulation experiments, most of them with real plant data. In short, the contributions of this thesis can be classified into three categories: a) Contributions to the modeling of hybrid systems (with several energy sources) of renewable generation, including hierarchical structures, whose results offer resources on how to model several real situations in renewable systems; b) Analysis of the use of chance constraints (CC) in renewable generation systems, their concept and structuring in multivariable systems and their effects, both beneficial and harmful, to the system; and c) Proposal of an Offset-Free controller that allows to deal with eventual dynamics not modeled in hierarchical control structures, which allows the controller to find the optimal operating point of the real plant and not only of the model used by the controller

**Keywords:** Model Predictive Control. Real-Time Optimization. Offset-Free. Renewable Energy.

## LISTA DE FIGURAS

Figura 1 – Matriz de geração elétrica brasileira . . . . .	19
Figura 2 – Participação de fontes renováveis para a geração de energia elétrica. . . . .	20
Figura 3 – Diagrama de blocos do algoritmo de um Controlador Preditivo Baseado em Modelo (MPC). . . . .	31
Figura 4 – Camadas dos sistemas de automação e controle industriais. . . . .	34
Figura 5 – Estratégia de controle <i>Dynamic Real Time Optimization</i> (DRTO). . . . .	36
Figura 6 – Arranjo dos campos solares na configuração CP . . . . .	44
Figura 7 – Arranjo dos campos solares na configuração CS . . . . .	45
Figura 8 – Primeiro cenário de irradiações para os diferentes campos <sup>5</sup> . . . . .	48
Figura 9 – Temperatura da água de entrada e ambiente aplicada aos campos solares . . . . .	48
Figura 10 – Temperatura de saída e vazão do arranjo na configuração CP . . . . .	49
Figura 11 – Temperatura de saída e vazão do arranjo na configuração CS . . . . .	49
Figura 12 – Temperatura e vazão do arranjo na configuração CP com a possibilidade de desativação de campos sob irradiação reduzida 70% . . . . .	49
Figura 13 – Vazão dos campos na configuração CP com a possibilidade de desativação de campos sob irradiação reduzida 70% . . . . .	50
Figura 14 – Aumento da quantidade de calor absorvido no arranjo CP, em comparação ao CS, para diferentes irradiações . . . . .	51
Figura 15 – Temperatura dos campos na configuração CP sob irradiação reduzida 70% . . . . .	51
Figura 16 – Função Densidade de Probabilidade e Densidade de Probabilidade Acumulada padrão. Adaptado de (PINHEIRO <i>et al.</i> , 2012). . . . .	54
Figura 17 – Variância da variável aleatória aumentando ao longo do horizonte de predição $N$ . . . . .	63
Figura 18 – Efeito da restrição probabilística que se enrijece (fica mais restritiva) ao longo do horizonte de predição $N$ . . . . .	64
Figura 19 – Covariância de malha fechada: covariância do primeiro instante de predição sendo utiliza como valor constante para todo o horizonte $N$ . . . . .	65
Figura 20 – Perfil de irradiações para os diferentes campos solares . . . . .	66
Figura 21 – Temperatura ambiente e de entrada para os quatro campos solares . . . . .	66
Figura 22 – Temperatura de saída dos campos para o <i>MPC1</i> e <i>MPC2</i> . . . . .	67
Figura 23 – Vazão dos campos para o <i>MPC1</i> e <i>MPC2</i> . . . . .	68
Figura 24 – Temperatura e vazão do arranjo para o <i>MPC1</i> e <i>MPC2</i> . . . . .	69
Figura 25 – Caso de estudo analisado: Planta de geração de energia híbrida . . . . .	74
Figura 26 – Regras para atendimento do contrato de venda de energia . . . . .	76
Figura 27 – Estrutura de controle hierárquico proposta . . . . .	78
Figura 28 – Rede Neural Artificial . . . . .	79
Figura 29 – Estimação da velocidade do vento com a técnica NN do preditor H-H . . . . .	80

Figura 30 – Estimação da irradiação solar com a técnica NN do preditor H-H . . . . .	80
Figura 31 – Estimação da velocidade do vento com a técnica NN do preditor Preditor diário (D-D) . . . . .	82
Figura 32 – Estimação da irradiação solar com a técnica NN do preditor D-D . . . . .	82
Figura 33 – PDF e CDF do erro de previsão do estimador H-H da soma das fontes não despacháveis de energia . . . . .	84
Figura 34 – PDF e CDF do erro de previsão do estimador D-D da soma das fontes não despacháveis de energia . . . . .	85
Figura 35 – PDF e CDF da entrada de cana-de-açúcar . . . . .	86
Figura 36 – Sistema de Supervisão e de Tomada de Decisão Proposto . . . . .	88
Figura 37 – Diferentes Cenários de Entrada de cana-de-açúcar . . . . .	91
Figura 38 – Perturbações: Velocidade do vento, irradiância e entrada de biogás . . . . .	92
Figura 39 – Demandas do processo . . . . .	93
Figura 40 – Resultados de Simulação: Primeiro cenário (Alta entrada de cana-de-açúcar)	95
Figura 41 – Resultados de Simulação: Segundo cenário (Entrada de cana-de-açúcar alta)	96
Figura 42 – Resultados de Simulação: Terceiro cenário (Baixa entrada de cana-de-açúcar)	97
Figura 43 – Fluxo de energia das Microrredes . . . . .	101
Figura 44 – Disposição das usinas (microrredes) envolvidas - São Paulo, Brasil. . . . .	102
Figura 45 – Perfil de demanda interna de energia elétrica de uma usina de cana-de-açúcar no Brasil . . . . .	102
Figura 46 – Estrutura Hierárquica (EMS) Proposta . . . . .	108
Figura 47 – Esquema do RTO . . . . .	115
Figura 48 – Representação Esquemática das MGCCs . . . . .	118
Figura 49 – Cenário 1: Irradiação Solar . . . . .	120
Figura 50 – Cenário 1: Entrada de Biomassa . . . . .	120
Figura 51 – Cenário 1: Produção de Energia . . . . .	121
Figura 52 – Cenário 1: Estado de Carga das Baterias . . . . .	121
Figura 53 – Cenário 1: Nível do Estoque de Biomassa . . . . .	122
Figura 54 – Cenário 2: Entrada de Biomassa . . . . .	123
Figura 55 – Cenário 2: Produção de Energia . . . . .	124
Figura 56 – Cenário 2: Estado de Carga da Bateria . . . . .	124
Figura 57 – Cenário 2: Gestão da Biomassa . . . . .	125
Figura 58 – Cenário 2: Estoque de Biomassa . . . . .	125
Figura 59 – Processo dos quatro tanques. . . . .	145
Figura 60 – Saída- Sistema controlado pelo Controlador MPC para Tracking com erro de modelagem: planta não linear real e modelo do controlador linearizado. . . . .	146
Figura 61 – Saída do Sistema e Setpoints ótimos - Sistema controlado pelo Controlador MPC para Tracking com erro de modelagem: planta não linear real e modelo do controlador linearizado. . . . .	146

Figura 62 – Saída- Sistema controlado pelo Controlador MPC Econômico de uma Camada com erro de modelagem: planta não linear real e modelo do controlador linearizado).	147
Figura 63 – Saída do Sistema e Setpoints ótimos - Sistema controlado pelo Controlador MPC Econômico de uma Camada com erro de modelagem: planta não linear real e modelo do controlador linearizado.	148
Figura 64 – Valor da compensação do termo $\lambda_{u,k}^T(u - \bar{u}(k))$	148
Figura 65 – Valor da compensação de $\epsilon(k)$	149
Figura 66 – Sistema de um Campo Solar de Grande Porte	150
Figura 67 – Irradiações para os quatro setores do campo solar.	150
Figura 68 – Temperatura de entrada ( $T_j$ ) e Temperatura ambiente ( $T_a$ ) para os quatro setores do campo solar.	151
Figura 69 – Temperatura dos quatro setores do campo de grande porte para o cenário 1	152
Figura 70 – Vazão dos quatro setores do campo de grande porte para o cenário 1	153
Figura 71 – Temperatura final do campo de grande porte para o cenário 1	153
Figura 72 – Temperatura dos quatro setores do campo de grande porte para o cenário 2	154
Figura 73 – Vazão dos quatro setores do campo de grande porte para o cenário 2	155
Figura 74 – Temperatura final do campo de grande porte para o cenário 2	155
Figura 75 – Temperatura final do campo de grande porte para os cenários 1 e 2	156
Figura 76 – Valor da compensação do termo $\lambda_{u,k}^T(u - \bar{u}(k))$	156
Figura 77 – Valor da compensação de $\epsilon(k)$	157
Figura 78 – Sistema de 4 tanques.	181

## LISTA DE TABELAS

Tabela 1 – Parâmetros do processo . . . . .	43
Tabela 2 – Variáveis do processo . . . . .	45
Tabela 3 – Volume de água e calor disponibilizados pelos arranjos CP e CS . . . . .	50
Tabela 4 – Integral do erro quadrático da temperatura de saída do arranjo . . . . .	67
Tabela 5 – Variação total do sinal de controle (vazão) dos campos TV . . . . .	68
Tabela 6 – Caso de estudo: Variáveis manipuladas . . . . .	74
Tabela 7 – Rede Neural utilizada para o preditor H-H . . . . .	79
Tabela 8 – Estimação de perturbações futuras: Erro médio relativo do preditor H-H . .	81
Tabela 9 – Rede Neural do Estimador diário D-D . . . . .	81
Tabela 10 – Estimação de perturbações futuras: Erro médio relativo do preditor D-D . .	81
Tabela 11 – Diferentes casos considerando os cenários de entrada de cana-de-açúcar . .	94
Tabela 12 – Parâmetros das Microrredes . . . . .	105
Tabela 13 – Informações Técnicas das Microrredes . . . . .	107
Tabela 14 – Índices de desempenho para os cenários 1 e 2 . . . . .	152
Tabela 15 – Parâmetros do processo . . . . .	180

## LISTA DE ABREVIATURAS E SIGLAS

CC	Restrições Probabilísticas ( <i>Chance Constraints</i> )
CDF	Função de Probabilidade Acumulada
CHP	Cogeração ( <i>Combined Heat and Power</i> )
CP	Campos em Paralelo
CS	Campos em série
D-D	Preditor diário
DNO	Operador da Rede de Distribuição de Energia ( <i>Distribution Network Operator</i> )
DRTTO	<i>Dynamic Real Time Optimization</i>
EMA	Erro Médio Absoluto
EMPC	MPC Econômico
EMS	Sistema de Gerenciamento de Energia
FF	Ação <i>Feedforward</i>
FSM	Máquina de Estados Finitos
H-H	Preditor de hora em hora
ISE	Erro Médio Quadrático ( <i>Integral Square Error</i> )
ISOPE	( <i>Integrated System Optimization and Parameter Estimation</i> )
LP	Programação Linear
MA	Adaptação via Modificadores ( <i>Modifier Adaptation</i> )
MG	Microrrede
MGCC	Controlador Central da Microrrede
MLP	Programação Inteira Mista
MPC	Controlador Preditivo baseado em Modelo
MPCT	MPC para <i>Tracking</i>
NN	Redes Neurais Auto-Regressivas Não Lineares
OCDE	Organização para a Cooperação e o Desenvolvimento Econômico
OP	Problema de Otimização
PDF	Função Densidade de Probabilidade
PID	Controlador Proporcional, Integral e Derivativo
PNMPC	<i>Practical Nonlinear Model Predictive Control</i>
QP	Programação Quadrática
RTO	Otimização em Tempo Real ( <i>Real Time Optimization</i> )
SSTO	<i>Steady State Target Optimizer</i>
TV	Variação Total da Ação de Controle ( <i>Total Variation</i> )

## LISTA DE SÍMBOLOS

$\ell$	Função Custo
$\mathcal{X}$	Conjunto de estados possíveis
$\mathcal{U}$	Conjunto de ações de controle possíveis
$\mathcal{X}_f$	Região Terminal
$\Omega$	Invariante de controle do sistema
$\rho$	Densidade da água
$C_p$	Calor específico da água
$A_a$	Seção reta do absorvedor
$T_{iF}$	Temperatura de entrada do campo solar
$T_{oF}$	Temperatura de saída do campo solar
$\eta$	Parâmetro do modelo
$H$	Coeficiente de perdas térmicas
$L_{eq}$	Comprimento equivalente do tubo absorvedor
$\beta_I$	Irradiância do modelo
$T_{oA}$	Temperatura de saída do arranjo
$\dot{m}_A$	Fluxo mássico do arranjo
$I$	Irradiação solar
$T_{iA}$	Temperatura de entrada do arranjo
$T_a$	Temperatura ambiente
$N$	Horizonte de previsão
$N_u$	Horizonte de Controle
$\Delta u$	Incremento da ação de controle
$u$	Ação de controle
$\alpha$	Coeficiente do modelo
$\beta$	Coeficiente do modelo
$\gamma$	Coeficiente do modelo
$q$	Perturbação
$\mu$	Média
$\sigma^2$	Variância
$\sigma$	Desvio padrão
$J$	Função Custo
$\mathbb{E}$	Esperança matemática
$\Sigma$	Matriz de covariância
$\rho$	Coeficiente de correlação
$x(k)$	Valor do estado no instante k
$Pr$	Operador Probabilidade
$\varphi$	Função de probabilidade acumulada
$I_n$	Matriz identidade de ordem n

$V_0$	Função custo de <i>offset</i>
$L$	Função Lagrangeana
$\mathcal{Y}$	Conjunto de soluções factíveis do problema
$\hat{x}(k)$	Estimação do estado para o instante $k$
$\mathcal{Z}$	Conjunto dos possíveis pontos de equilíbrio do sistema



## CONTEÚDO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>19</b>
1.1	MOTIVAÇÃO DA TESE	19
1.1.1	<b>Avaliação da topologia na eficiência de campos solares de grande porte</b>	<b>22</b>
1.1.2	<b>Utilização de técnicas probabilísticas no MPC frente a estocasticidade na geração renovável</b>	<b>23</b>
1.1.3	<b>Avaliação de técnicas probabilísticas em sistemas híbridos de geração renovável</b>	<b>23</b>
1.1.4	<b>Avaliação de técnicas multi-camada em sistemas cooperativos híbridos de geração renovável</b>	<b>25</b>
1.1.5	<b>Garantia de estabilidade no MPC para sistemas de operação variante no tempo considerando erro de modelagem entre planta e modelo</b>	<b>25</b>
1.2	OBJETIVOS E CONTRIBUIÇÕES DESTA TESE	27
1.2.1	<b>Modelagem e análise da topologia de uma planta heliotérmica</b>	<b>27</b>
1.2.2	<b>Uso de técnicas estocásticas em uma planta heliotérmica</b>	<b>27</b>
1.2.3	<b>Uso de técnicas estocásticas para o controle de uma usina de cana-de-açúcar</b>	<b>27</b>
1.2.4	<b>Uso de técnicas de controle hierárquico para o controle de várias usinas de cana de açúcar</b>	<b>28</b>
1.2.5	<b>Proposta de controlador MPC Econômico de uma camada com offset-free através de adaptação de modelo</b>	<b>28</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>29</b>
2.1	CONTROLADOR PREDITIVO BASEADO EM MODELO	29
2.2	ESTRATÉGIAS MPC COM CRITÉRIO ECONÔMICO NA FORMULAÇÃO	33
2.2.1	<b>Dynamic RTO (DRTO)</b>	<b>35</b>
2.2.2	<b>One-layer MPC</b>	<b>36</b>
2.2.3	<b>Economic MPC (EMPC)</b>	<b>37</b>
2.3	MPC - CONDIÇÕES DE ESTABILIDADE	38
2.4	COMENTÁRIOS FINAIS DO CAPÍTULO	40
<b>3</b>	<b>MODELAGEM, CONTROLE E ANÁLISE DA EFICIÊNCIA DE CAMPOS SOLARES DE GRANDE PORTE</b>	<b>41</b>
3.1	INTRODUÇÃO	41
3.2	DESCRIÇÃO DO PROCESSO	41
3.2.1	<b>Modelagem de um campo solar de grande porte</b>	<b>43</b>
3.3	CONTROLADOR PREDITIVO PNMPC	45
3.4	RESULTADOS	47

3.5	COMENTÁRIOS FINAIS DO CAPÍTULO . . . . .	52
<b>4</b>	<b>MODELAGEM ESTOCÁSTICA PARA O PROBLEMA DE CAMPOS SOLARES DE GRANDE PORTE . . . . .</b>	<b>53</b>
4.1	INTRODUÇÃO . . . . .	53
4.2	FUNDAMENTAÇÃO TEÓRICA . . . . .	53
4.2.1	<b>Modelagem Probabilística de uma Perturbação ao Sistema . . . . .</b>	<b>54</b>
4.2.2	<b>Inclusão da Incerteza no Modelo de um Sistema . . . . .</b>	<b>55</b>
4.2.3	<b>Restrições Probabilísticas . . . . .</b>	<b>57</b>
4.2.4	<b>Restrições probabilísticas e suas determinísticas equivalentes - Incerteza como variável gaussiana . . . . .</b>	<b>58</b>
4.3	ESTUDO DE CASO . . . . .	60
4.3.1	<b>Controle Preditivo PN MPC com uso de Predições das Perturbações . . . . .</b>	<b>60</b>
4.3.2	<b>Modelagem Probabilística . . . . .</b>	<b>61</b>
4.3.3	<b>Restrições Probabilísticas . . . . .</b>	<b>62</b>
4.3.4	<b>Resultados . . . . .</b>	<b>65</b>
4.3.5	<b>Comentários Finais do Capítulo . . . . .</b>	<b>68</b>
<b>5</b>	<b>CONTROLE PREDITIVO COM RESTRIÇÕES PROBABILÍSTICAS PARA O GERENCIAMENTO EFICIENTE DE ENERGIA EM SISTEMAS DE GERAÇÃO RENOVÁVEL . . . . .</b>	<b>70</b>
5.1	INTRODUÇÃO . . . . .	70
5.2	CASO DE ESTUDO - USINA DE CANA-DE-AÇÚCAR . . . . .	72
5.2.1	<b>Descrição da Usina . . . . .</b>	<b>72</b>
5.2.2	<b>O contrato de fornecimento de energia elétrica multi objetivo . . . . .</b>	<b>75</b>
5.3	SOLUÇÃO PROPOSTA . . . . .	77
5.3.1	<b>Estimador de Perturbações . . . . .</b>	<b>77</b>
5.3.1.1	Preditor de hora em hora (H-H) . . . . .	78
5.3.1.2	Preditor Diário D-D . . . . .	80
5.3.1.3	Restrições Probabilísticas (CC) . . . . .	82
5.3.2	<b>Camada de Decisão e Supervisão . . . . .</b>	<b>84</b>
5.3.3	<b>Camada de Controle . . . . .</b>	<b>88</b>
5.4	RESULTADOS . . . . .	90
5.5	COMENTÁRIOS FINAIS DO CAPÍTULO . . . . .	94
<b>6</b>	<b>SISTEMA DE GESTÃO DE ENERGIA DE DUAS CAMADAS PARA MICRORREDES COOPERATIVAS NA INDÚSTRIA DE CANA-DE-AÇÚCAR . . . . .</b>	<b>99</b>
6.1	INTRODUÇÃO . . . . .	99
6.2	FORMALIZAÇÃO DO PROBLEMA . . . . .	101
6.2.1	<b>Caso de Estudo . . . . .</b>	<b>101</b>
6.2.2	<b>Objetivo de geração de energia . . . . .</b>	<b>101</b>

6.2.3	<b>Restrições Operacionais</b> . . . . .	106
6.3	ESTRUTURA HIERÁRQUICA PROPOSTA . . . . .	106
6.4	CAMADA SUPERIOR DE CONTROLE: RTO EMS . . . . .	107
6.4.1	<b>Problema de Otimização</b> . . . . .	109
6.5	CAMADA INFERIOR: MPC MGCCS . . . . .	115
6.6	CASO DE ESTUDO . . . . .	119
6.6.1	<b>Cenário 1: Operação Normal</b> . . . . .	119
6.6.2	<b>Cenário 2: Fim de colheita</b> . . . . .	122
6.7	COMENTÁRIOS FINAIS DO CAPÍTULO . . . . .	123
7	<b>CONTROLADOR PREDITIVO ECONÔMICO DE UMA CAMADA</b>	127
7.1	MPC PARA <i>TRACKING</i> (MPCT) . . . . .	129
7.1.1	<b>Controlador MPCT - Cálculo da Região Terminal</b> . . . . .	131
7.2	ALGORITMOS DE IDENTIFICAÇÃO DE PARÂMETROS . . . . .	132
7.2.1	<b>Método das Duas Etapas (Two-Step Approach)</b> . . . . .	133
7.2.2	<b>ISOPE</b> . . . . .	134
7.2.3	<b>Metodologia de Adaptação via Modificadores</b> . . . . .	138
7.2.4	<b>MPC para Tracking de uma Camada (One-Layer MPCT)</b> . . . . .	140
7.2.5	<b>Estratégia baseada em Gradiente para o One-Layer MPCT</b> . . . . .	140
7.2.6	<b>Controlador MPC Econômico de uma Camada</b> . . . . .	142
7.2.7	<b>Propriedades do Controlador MPC Econômico de uma Camada</b> . . . . .	144
7.3	EXEMPLO ILUSTRATIVO . . . . .	144
7.4	APLICAÇÃO DO CONTROLADOR MPC ECONÔMICO DE UMA CAMADA - CAMPO SOLAR DE GRANDE PORTE . . . . .	149
7.4.1	<b>Cenário 1 - Controlador sem a utilização dos Modificadores MA</b> . . . . .	151
7.4.2	<b>Cenário 2 - Controlador com a utilização dos Modificadores MA</b> . . . . .	151
7.5	COMENTÁRIOS FINAIS DO CAPÍTULO . . . . .	157
8	<b>CONCLUSÕES</b> . . . . .	158
8.1	LISTA DE PUBLICAÇÕES . . . . .	159
8.2	TRABALHOS FUTUROS . . . . .	160
	<b>REFERÊNCIAS</b> . . . . .	162
	<b>ANEXO A – TRANSFORMAÇÃO LINEAR DE UMA VARIÁVEL ALEATÓRIA MULTIVARIÁVEL</b> . . . . .	179
	<b>ANEXO B – MODELAGEM DO SISTEMA DE QUATRO TANQUES</b> . . . . .	180

# 1 INTRODUÇÃO

O objetivo desta seção é apresentar a motivação desta tese, ou seja, a problemática a ser enfrentada e a sua contextualização, colocando os elementos teóricos que a cercam e os desafios a serem superados. Adicionalmente, apresentam-se as contribuições em linhas gerais e as publicações alcançadas.

## 1.1 MOTIVAÇÃO DA TESE

Sistemas eficientes, sustentáveis e diversificados de geração de energia elétrica são uma preocupação crescente na maioria dos países. A matriz de geração de energia elétrica brasileira (Figura 1) está baseada, principalmente, em recursos hídricos, correspondendo a 60,83% da energia elétrica produzida no país. O combustível fóssil é responsável por 14,83%, a biomassa por 8,45%, a energia eólica por 8,84%, a nuclear por 1,13% e a solar por 1,29% (ANEEL, 2019). A Figura 2 mostra que, atualmente, a matriz elétrica brasileira tem uma participação de 88,8% de fontes renováveis, enquanto que a média mundial é 19,5% e, entre os países membros da Organização para a Cooperação e Desenvolvimento Econômico (Organização para a Cooperação e o Desenvolvimento Econômico (OCDE)), a média é 18,3% (AGÊNCIA-BRASIL, 2015).




Figura 1 – Matriz de geração elétrica brasileira

Por outro lado, com o crescimento da utilização da energia renovável gerada por pequenas unidades de geração distribuídas, surgem alguns problemas recorrentes ligados à confiabilidade do sistema e à qualidade da energia gerada, já que as fontes de energia (sol, vento, etc) são intermitentes e estas variações podem ocasionar flutuações imprevisíveis na saída do sistema de potência (ANDERSON; LEACH, 2004). O fato da geração de energia proveniente de fontes renováveis não estar sujeita à demanda pode causar desequilíbrios no sistema. Uma maneira de evitar esse problema é inserir formas intermediárias de armazenamento de energia, tais como baterias, super capacitores e volantes de inércia (DELL; RAND, 2001),

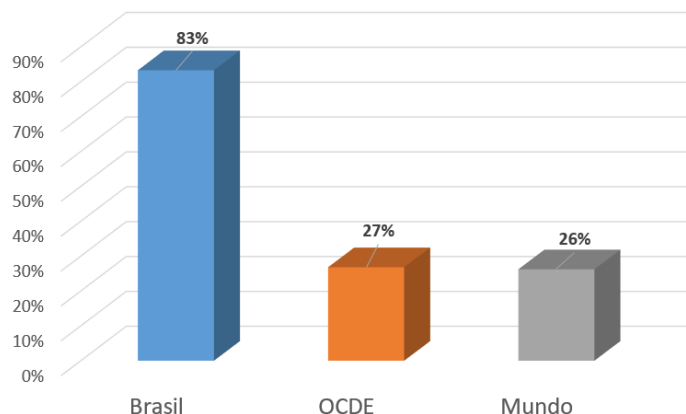


Figura 2 – Participação de fontes renováveis para a geração de energia elétrica.

minimizando os efeitos das variações e flutuações inerentes ao processo de geração desse tipo de energia.

No contexto da diversidade de fontes de energia renováveis, a energia elétrica gerada por biomassa proveniente do bagaço de cana-de-açúcar compõe 6,6% da matriz energética brasileira (ANEEL, 2019), colocando a indústria sucroalcooleiras como uma importante fonte de energia no cenário nacional. Nos trabalhos de Costa *et al.* (2014) e Costa *et al.* (2012) nota-se tal relevância que, aliada ao fato das usinas de açúcar e etanol estarem localizadas, em geral, onde a insolação anual é considerada alta para os padrões nacionais (algo em torno de 2500 a 3000 horas de sol por ano). Tais características fazem das plantas sucroalcooleiras atores importantes no sistema de geração renovável brasileira, pois é possível agregar sistemas de geração de energia solar aos de geração por biomassa, transformando as usinas de cana de açúcar em microrredes de geração híbrida (MORATO, Marcelo Menezes *et al.*, 2016a) (MORATO, Marcelo Menezes *et al.*, 2017) (MORATO, Marcelo Menezes *et al.*, 2016b).

Portanto, pode-se afirmar que o controle e a gestão de sistemas de geração de energia, incluindo energia renovável e não-renovável, é um problema importante a ser estudado no Brasil dadas as características da nossa matriz energética e pela necessidade de alcançar níveis elevados de eficiência na geração e armazenamento da energia. As características dos sistemas de geração de energia renovável, como a estocasticidade das fontes de energia (sol, vento, biogás, biomassa, etc) e a necessidade do atendimento da demanda elétrica frente às flutuações do sistema configuram um problema desafiador de cunho teórico com aplicações práticas.

Uma das técnicas de controle candidatas para enfrentar esse problema é o chamado Controlador Preditivo Baseado em Modelo (Controlador Preditivo baseado em Modelo (MPC)) que é uma família de técnicas de controle que faz uso de um modelo para prever o comportamento futuro do processo e, com base nessas previsões, minimizar uma função de custo que, geralmente, pondera o erro de seguimento de referências e o movimento das ações de controle, considerando um conjunto de restrições nas variáveis envolvidas (E. CAMACHO; C. BORDONS, 2007). No caso particular desse tipo de sistemas, previsões de demanda e de disponibilidade de energia podem ser consideradas no problema de controle, o que torna o

controlador preditivo baseado em modelo (MPC) uma estratégia interessante (SERNA *et al.*, 2015), já que uma das propriedades do MPC é a possibilidade de tratar de forma natural valores futuros de referências e perturbações que afetem o sistema, dado que modelos internos são usados para a formulação da lei de controle (CAMACHO; BORDONS, 2004).

Adicionalmente, o MPC permite considerar na sua formulação questões relacionadas à otimização econômica junto aos requisitos de operação de processo. Esta junção dos problemas econômico e de processo pode ser tratada de diferentes formas, com uma camada de otimização separada em outra taxa de amostragem, problema conhecido como RTO-MPC (*real-time optimization MPC*) (FINDEISEN *et al.*, 1980) ou, alternativamente, de forma integrada na mesma função custo, no denominado MPC Econômico (EMPC) (RAWLINGS, J. B. *et al.*, 2012a). A sintonia e adequação dessas soluções, assim como estudos de estabilidade e robustez são um tema de pesquisa atual na área.

Tradicionalmente, sistemas de otimização econômica e controle industriais têm sido propostos baseados em uma estrutura hierárquica multi-camadas (RTO-MPC) (FINDEISEN *et al.*, 1980) dividindo o problema de otimização com o intuito de simplificá-lo (CAMPOS *et al.*, 2013). Essa estrutura, de forma geral, tem uma primeira camada (superior) de planejamento onde definem-se os objetivos macro da empresa, como quantidade de vendas, estoque e produção. Na camada seguinte (RTO), considera-se uma função objetivo econômica sujeita às restrições do sistema para encontrar o ponto de operação que seja economicamente mais viável utilizando um modelo complexo mas sem considerar as dinâmicas do processo. Por sua vez, a camada do controle avançado (MPC) é a responsável por estabelecer a melhor trajetória das variáveis manipuladas para atingir o ponto de operação indicado pelo RTO, utilizando modelos dinâmicos. A última camada tem o papel de manter as variáveis controladas nos valores requeridos pela camada anterior, fazendo uso de controladores locais SISO, como Controlador Proporcional, Integral e Derivativo (PID).

Um outro aspecto importante na geração de energia elétrica utilizando fontes renováveis é a forma como se enfrenta a incerteza que há tanto na produção quanto na demanda da energia elétrica. Apesar da maioria dos trabalhos publicados na área concentrarem-se em técnicas determinísticas, métodos estocásticos têm sido pesquisados apresentando resultados promissores na captura das incertezas associadas à geração de energia utilizando fontes renováveis (SU *et al.*, 2013), (LIANG; ZHUANG, 2014). Por outro lado, incertezas nas restrições dos problemas de otimização, o que é comum nos problemas de engenharia (ACKOOIJ, 2013), também podem ser modeladas como restrições probabilísticas e têm sido tema recente em pesquisa na área de energias renováveis (CANNON *et al.*, 2009; ROALD *et al.*, 2013; JIANZHE *et al.*, 2016; VELARDE *et al.*, 2016; LUBIN *et al.*, 2015; YO *et al.*, 2014; WANG, Q. *et al.*, 2012) e configuram um tema importante a ser estudado.

Entretanto, segundo David Mayne (2016), muitas propostas de MPC Robusto e Estocástico são provavelmente muito complexas para a implementação nas indústrias de processos, onde a maioria das aplicações é encontrada e, normalmente, incentiva-se o desenvolvimento

de alternativas mais simples. Existem pesquisas que apresentam soluções nesse sentido, como o trabalho de Souza *et al.* (2010) onde os autores utilizam uma formulação com base no gradiente da função econômica para um controlador de uma camada (RTO+MPC), posteriormente analisando a estabilidade (ALAMO, Teodoro *et al.*, 2014). Em outro trabalho, Alvarez e Odloak (2010) apresentam proposta de controlador MPC em três camadas (Otimização em Tempo Real (*Real Time Optimization*) (RTO)/Programação Quadrática (QP)/MPC) capaz de operar com incertezas no modelo e tolerar grandes variações entre os pontos de operação ótimos. Um dos objetivos desta tese é explorar soluções práticas possíveis de utilizar no contexto do MPC com características estocásticas.

Além das dificuldades relatadas por David Mayne (2016), no que tange à aplicação de técnicas estocásticas em controladores MPC, Sartori (2017) afirmou que a complexidade dos sistemas de energia híbridos em processos industriais requer a utilização de modelos complexos que inviabilizam ou dificultam a aplicação das estratégias de controle MPC Econômico com garantia de estabilidade. Dessa forma, este trabalho tem como um dos objetivos apresentar um controlador preditivo baseado em modelo que possua garantia de estabilidade e que permita enfrentar características estocásticas do problema a ser solucionado.

Em suma, nesta tese apresentam-se<sup>1</sup> algumas propostas para solução dos problemas citados que vão desde configurações de planta e do sistema de controle no âmbito da geração de energia renovável até novas estratégias de MPC com garantia de estabilidade e possibilidade de implementação prática. Os principais pontos abordados nesta tese são os seguintes:

- Avaliação da topologia na eficiência de campos solares de grande porte;
- Incorporação de técnicas probabilísticas na formulação do MPC frente a estocasticidade da geração renovável;
- Avaliação de técnicas probabilísticas em sistemas híbridos de geração renovável;
- Avaliação de técnicas multi-camada em sistemas híbridos cooperativos de geração renovável;
- Garantia de estabilidade no MPC para sistemas de operação variante no tempo considerando erro de modelagem entre planta e modelo;

A seguir, explora-se um pouco mais cada um desses itens para, no decorrer da tese, explaná-los detalhadamente.

### 1.1.1 Avaliação da topologia na eficiência de campos solares de grande porte

Em campos solares de grande porte é comum que a irradiação solar alcance valores diferentes para cada setor do campo durante o dia devido à passagem de nuvens localizadas.

<sup>1</sup> É importante destacar que todas as implementações feitas nesta tese foram desenvolvidas em linguagem Matlab, sendo que a única rotina pronta utilizada foi o solver de otimização, ou seja, todo o código foi programado manualmente.

Esta situação configura um problema difícil de tratar devido à característica estocástica da irradiação solar e à dinâmica acoplada dos setores do campo sujeitos a diferentes perturbações, já que, ao existir a recirculação do fluido, o efeito das perturbações na temperatura de saída de cada setor do campo pode afetar a temperatura de entrada dos demais setores do campo, configurando a interdependência entre eles. Para verificar as diferenças de eficiência entre campos com topologias diferentes, modelaram-se campos solares nas configurações série e paralelo (setores conectados em série e em paralelo) e comparou-se o desempenho de tais campos sujeitos à passagem de nuvens. O experimento foi feito em simulação, porém utilizando dados reais da plataforma solar de Almería, na Espanha. Demonstrou-se a vantagem de utilizar a configuração em paralelo por possibilitar a desativação de campos cuja irradiação fosse insuficiente.

### **1.1.2 Utilização de técnicas probabilísticas no MPC frente a estocasticidade na geração renovável**

Ainda tratando de campos solares de grande porte, é comum que o controle destes sistemas seja complexo devido à característica estocástica da irradiação solar, cuja variação pode ser muito rápida e de grande amplitude, além de que em problemas envolvendo controle preditivo baseado em modelo pode-se enfrentar, dentre outras coisas, dificuldades para atender às restrições nas variáveis de saída e/ou estados do processo, uma vez que as incertezas ocasionam previsões também incertas. Para minimizar esse problema é possível incorporar as incertezas ao modelo e reescrever as restrições de forma probabilística melhorando a robustez do MPC (SCHWARM, Alexander T.; NIKOLAOU, 1999a). A abordagem de restrições probabilísticas permite estabelecer o risco de violação da restrição original desde que o comportamento estocástico das perturbações possa ser modelado por uma Função Densidade de Probabilidade (PDF) de uma variável aleatória e esta informação seja inserida no modelo de previsão. Neste trabalho aborda-se o conceito de restrições probabilísticas (BOYD; VANDENBERGHE, 2004; CHARNES; COOPER, 1969) aplicado ao problema dos campos solares de grande porte, demonstrando que o controlador consegue seguir mais facilmente a referência de temperatura sem perder a factibilidade por violação das restrições do problema de otimização.

### **1.1.3 Avaliação de técnicas probabilísticas em sistemas híbridos de geração renovável**

O cenário energético brasileiro possui uma matriz energética diversificada, e a integração de novas fontes renováveis aos sistemas de geração de energia já existentes é uma alternativa para atender à demanda de energia de forma sustentável. Entretanto, um dos grandes desafios é integrar essas novas fontes de energia sem perder eficiência e disponibilidade do fornecimento contínuo, ou seja, mantendo a despachabilidade do sistema.

Em particular, as usinas de processamento de cana-de-açúcar podem ser vistas como unidades geradoras de energia renovável e, dada a importância desse tipo de geração no cenário



energético brasileiro, justifica-se o estudo e a pesquisa direcionadas a essa área. Tais usinas utilizam subprodutos da fabricação do açúcar e do etanol para gerar energia, suprindo sua própria demanda e vendendo o excedente ao mercado brasileiro de energia elétrica. Aliado ao fato de serem importantes unidades geradoras de energia, muitas usinas de açúcar e etanol estão localizadas onde a insolação anual é considerada alta para os padrões nacionais. Esta condição permite a integração de geração solar a tais usinas, elevando o potencial de geração de energia das plantas sucroalcooleiras no cenário energético brasileiro, o que possibilitaria que usinas de cana-de-açúcar se tornem microrredes de geração híbrida (MORATO, Marcelo Menezes *et al.*, 2016a) (MORATO, Marcelo Menezes *et al.*, 2017) (MORATO, Marcelo Menezes *et al.*, 2016b).

O controle da geração e armazenamento de energia em sistemas híbridos, incluindo fontes renováveis e não renováveis é um tema que vem sendo estudado (GREENWELL; VAHIDI, 2010) (FERRARI-TRECATE *et al.*, 2004). Uma forma de modelar esse tipo de sistema é através da abordagem de microrredes, onde o sistema é modelado como uma microrrede com várias fontes de energia disponíveis, com o objetivo de gerir e planejar tanto a geração quanto a utilização da energia. É comum dividir a operação de microrredes em três níveis de controle hierárquico. Os problemas de instrumentação e comunicação são analisados em um primeiro nível. A operação local dos subsistemas é gerenciada no segundo nível, enquanto que o planejamento de energia é realizado no terceiro nível, ou nível terciário. Portanto, este trabalho está relacionado ao nível terciário, ou seja no âmbito do gerenciamento das fontes de energia disponíveis.

Alguns trabalhos utilizam especificamente Controle Preditivo (*MPC*) para o gerenciamento de energia em microrredes com fontes renováveis. Entretanto, dadas as características estocásticas das fontes de energia é necessário considerar este tipo de comportamento no desenvolvimento das técnicas de controle para sistemas híbridos de energia. Alguns trabalhos recentes consideram o gerenciamento de energia para microrredes com distúrbios estocásticos, como Meibom *et al.* (2011), Yu *et al.* (2013) e, também, Hovgaard *et al.* (2011).

No entanto, um dos problemas importantes no contexto do *MPC* em sistemas estocásticos é a garantia do atendimento das restrições. Uma das técnicas que permitem considerar a estocasticidade das fontes de energia são as chamadas *Chance Constraints (CC)* ou Restrições Probabilísticas. As *CC* permitem projetar o controlador que garanta o atendimento das restrições de forma probabilística, ou seja, que o risco do não atendimento das restrições, quando isto for permitido pelo processo, esteja parametrizado, sendo que esta abordagem provou ter inúmeras aplicações em engenharia. Algumas aplicações das *CC* para usinas de energia renovável podem ser vistas nos trabalhos de Lubin *et al.* (2016), Olivares *et al.* (2015), Ran Wang *et al.* (2014) e Su *et al.* (2014).

Nesta tese é apresentado um estudo de caso de uma usina de processamento de cana-de-açúcar como usina geradora de energia renovável, considerando no projeto do controlador *MPC* o atendimento probabilístico das restrições.

#### 1.1.4 Avaliação de técnicas multi-camada em sistemas cooperativos híbridos de geração renovável

Considerando a tendência crescente do paradigma da geração distribuída (BORBELY; KREIDER, 2001), especialmente no que tange às pequenas e médias unidades, no que diz respeito ao compartilhamento de recursos e ao controle das unidades geradoras é um tema relevante, especialmente quando se trata do uso de energia renovável. Uma das estratégias de controle para sistemas complexos é o controle hierárquico, que divide o problema, como já foi mencionado, para simplificá-lo. É comum que sejam utilizados controladores em diferentes posições hierárquicas para que cada um se encarregue de resolver o problema sob diferentes aspectos. Entretanto, alguns problemas característicos dessa estratégia surgem, como divergência entre modelos das diversas camadas e o tratamento de perturbações em cada uma delas. Nesta Tese apresenta-se o projeto de um Sistema de Gerenciamento de Energia (Sistema de Gerenciamento de Energia (EMS)) em nível terciário (a exemplo do capítulo anterior), com fontes renováveis envolvendo várias microrredes cooperando entre si, situação esta que pode ser uma alternativa para aumentar a participação das fontes renováveis na matriz energética Brasileira. O estudo de um caso brasileiro é apresentado juntamente com simulações numéricas com modelos baseados em dados reais.

#### 1.1.5 Garantia de estabilidade no MPC para sistemas de operação variante no tempo considerando erro de modelagem entre planta e modelo

A abordagem hierárquica RTO-MPC pode apresentar inconsistência na comunicação entre a camada de RTO e do MPC, decorrente das discrepâncias entre os modelos utilizados em cada camada (ALAMO, Teodoro *et al.*, 2014). Uma das implicações dessa abordagem é a possibilidade de que um determinado estado estacionário fornecido pelo RTO seja um ponto infactível (inalcançável) para o MPC frente a eventuais mudanças significativas do problema de otimização. Tais mudanças podem ser, por exemplo, no conjunto de restrições ou proveniente da diferença entre o modelo do RTO e do MPC, assim como os erros de modelagem entre a planta real e os modelos utilizados, que podem ser paramétricos e/ou estruturais.<sup>2</sup> Para contornar este problema, uma das alternativas é a utilização de uma camada intermediária entre o RTO e o MPC chamada de *Steady State Target Optimizer* (SSTO) cuja função é, dada uma referência fornecida pelo RTO, calcular um ponto estacionário *factível* a ser repassado para o MPC.

Uma das técnicas que surge em meio aos avanços da *Real Time Optimization* é uma metodologia chamada de adaptação via modificadores (*Modifier Adaptation - MA*) que enfrenta o erro de modelagem fazendo correções no problema de otimização ao incluir termos (modificadores) nas restrições e na função de custo (ou no próprio modelo), fazendo com

<sup>2</sup> É entendido como um erro paramétrico quando a estrutura do modelo é conhecido e apenas o valor de um ou mais coeficientes (parâmetros) é desconhecido. O erro estrutural indica que não se conhece parte da estrutura do modelo.

que a saída do modelo e a do processo real convirjam (MARCHETTI, A. *et al.*, 2009). Os fundamentos da técnica de adaptação via modificadores serão apresentados e detalhados no decorrer desta Tese.

Por outro lado, dentro do contexto do controle hierárquico, outra dificuldade que deve ser enfrentada pelos controladores é a constante mudança ou atualização do ponto de operação (ou *setpoint*), de forma que o controlador deve, de alguma forma, ser capaz de levar o sistema ao novo ponto de operação levando em conta os seus critérios de desempenho sem violar as restrições do problema de otimização. Além de não ser uma operação trivial, é necessário que o sistema tenha garantia de estabilidade de forma que o controlador ofereça sempre uma possível solução para o problema de otimização. No trabalho de Ferramosca (2011), citam-se alguns trabalhos que enfrentam o problema chamado de seguimento de setpoint, como Becerra *et al.* (1998) que divide o controlador superior em duas camadas, sendo que a camada inferior trata da regulação do sistema, enquanto que a superior tem a tarefa de adaptar o controlador ao novo setpoint. Outro tipo de controladores avançados adaptativos são os chamados *reference governors* (GILBERT, E. *et al.*, 1994) cujo objetivo é, de certa forma, gerenciar as referências a fim de evitar a violação das restrições quando houver mudanças de setpoint. Uma das técnicas mais bem sucedidas é o Controlador Preditivo Baseado em Modelo dada a sua natureza de calcular a cada passo a ação de controle ótima para os critérios estabelecidos, permitindo que haja mudanças no ponto de operação do sistema.

Um dos controladores MPC que enfrenta os problemas de inconsistência entre modelos e de mudanças nos pontos de operação do sistema é o chamado MPC para Tracking (MPCT) (LIMON *et al.*, 2008), que consiste em um controlador preditivo com garantia de estabilidade que integra a camada de SSTO na sua formulação de forma que, dado um setpoint calculado pela camada superior de RTO, o MPCT encontra um ponto factível para o controlador que seja o mais adequado (por exemplo, o mais cercano desse *setpoint*) respeitando as restrições do sistema.

O controlador MPCT integra a camada SSTO utilizando as chamadas referências artificiais, que são as referências alcançáveis pelo modelo do controlador definidas como variáveis de otimização. Desta forma, o controlador pode, além de garantir a factibilidade, permitir que a formulação com garantia de estabilidade seja alcançada, mesmo com mudanças bruscas no ponto de operação do sistema sem precisar recalcular os elementos terminais que garantem a estabilidade do sistema.

Neste trabalho apresenta-se uma extensão do trabalho de D. Limon *et al.* (2013) (*One-Layer MPC for Tracking*), acrescentando a conveniente adaptação do modelo formalizada por A. Marchetti *et al.* (2009) (*Modifier Adaptation*) para contornar as dificuldades de implementação relacionadas na aplicação de controle preditivo a sistemas estocásticos com garantia de estabilidade.

## 1.2 OBJETIVOS E CONTRIBUIÇÕES DESTA TESE

O objetivo desta Tese é desenvolver e aplicar, com base em estratégias de controle preditivo, sistemas de controle e otimização econômica para problemas práticos nos processos de geração e gestão de energia, principalmente considerando o comportamento estocástico dos sistemas com fontes de energia renováveis.

De maneira geral, este trabalho está dividido em duas partes: a primeira é investigar soluções com base em estratégias de controle preditivo para problemas práticos na área de energias renováveis (o que pode ser realizado sem necessidade de incluir garantias de estabilidade de forma analítica); e a segunda é estudar os aspectos relativos às condições de estabilidade buscando soluções teóricas com possibilidade de aplicação em sistemas reais de grande porte. Convém esclarecer que as primeiras implementações práticas deste trabalho, que tinham inicialmente a intenção de investigar a aplicação de controladores MPC a sistemas de geração de energia renovável, foram realizadas utilizando o algoritmo PNMPC (*Practical Nonlinear Model Predictive Control*) com ponderações no incremento da ação de controle sendo que, somente após tais implementações, surgiu a motivação de investigar a estabilidade, inclusive na configuração RTO-MPC. Desta forma, a despeito da abordagem linearizante do algoritmo PNMPC, no último capítulo desta tese é utilizada a modelagem e formulação do controlador na forma de espaço de estados considerando o conhecimento do estado completo (ou estimado) e ponderação do valor absoluto da ação de controle, modelagem esta que permite prosseguir com a análise da garantia de estabilidade.

A seguir, serão apresentadas as principais contribuições da Tese separadas por capítulos.

### 1.2.1 Modelagem e análise da topologia de uma planta heliotérmica

No capítulo 3, modelou-se uma planta heliotérmica controlada por um MPC e investigaram-se os efeitos de mudanças na topologia do sistema analisando a quantidade de energia captada pelas diferentes configurações.

### 1.2.2 Uso de técnicas estocásticas em uma planta heliotérmica

Adicionalmente, no capítulo 4 investigou-se a utilização de técnicas probabilísticas para enfrentar a estocasticidade proveniente da irradiação solar e seus efeitos no sistema heliotérmico controlado por um controlador MPC.

### 1.2.3 Uso de técnicas estocásticas para o controle de uma usina de cana-de-açúcar

No capítulo 5 apresenta-se um estudo de caso onde utilizam-se as ferramentas de MPC estocástico para enfrentar a dificuldade de controlar uma usina de cana de açúcar modelada como uma unidade de geração de energia híbrida.

### 1.2.4 Uso de técnicas de controle hierárquico para o controle de várias usinas de cana de açúcar

No capítulo 6 apresenta-se outro estudo de caso de um conjunto de usinas de cana-de-açúcar que, utilizando técnicas de controle hierárquico, devem cooperar para atingir os objetivos globais de produção e fornecimento de energia.

### 1.2.5 Proposta de controlador MPC Econômico de uma camada com offset-free através de adaptação de modelo

Um dos objetivos da Tese é o desenvolvimento de novas estratégias de controle MPC levando em conta os aspectos econômico e estocástico, aliado às condições de estabilidade desse tipo de controlador, no sentido de possibilitar a sua aplicação à realidade, principalmente, à dos sistemas de geração de energia. Diante disso, no capítulo 7 propõe-se um controlador MPC Econômico de uma camada com *offset-free*, que possa integrar elementos do modelo do RTO e que, ao mesmo tempo, seja realimentado com as informações das saídas do processo real para corrigir eventuais erros de modelagem tanto do MPC quanto do RTO. Ainda, explora-se a abordagem estocástica da proposta para que possam ser consideradas eventuais características estocásticas de elementos do sistema, como a irradiação solar e a velocidade do vento.

De certa forma, uma das contribuições desta Tese é agregar, em uma solução única, elementos considerados separadamente nos trabalhos

- MPC for tracking piecewise constant references for constrained linear systems (LIMON *et al.*, 2008);
- Integrating the RTO in the MPC: an adaptive gradient-based approach (LIMON, D. *et al.*, 2013);
- Real-Time Optimization via Modifier Adaptation Integrated with Model Predictive Control (MARCHETTI, A. *et al.*, 2011);
- Modifier-Adaptation Methodology for Real-Time Optimization (MARCHETTI, A. *et al.*, 2009);
- Steady-state target optimization designs for integrating real-time optimization and model predictive control (MARCHETTI, A. *et al.*, 2013);
- Linear offset-free Model Predictive Control (MAEDER *et al.*, 2009)
- Chance Constrained Model Predictive Control (SCHWARM, Alexander T.; NIKOLAOU, 1999a).

resultando em um controlador MPC com abordagem *offset-free* integrando elementos e técnicas provenientes da teoria de RTO de forma a obter uma solução aplicável a problemas reais e que possa adaptar-se para corrigir eventuais erros de modelagem.

## 2 FUNDAMENTAÇÃO TEÓRICA

A utilização dos recursos oferecidos pelas técnicas de otimização aplicadas ao controle de processos tem crescido nos últimos anos resultando em abordagens chamadas de controladores ótimos. Nesse contexto, há várias estratégias de controle ótimo, cada uma delas com suas restrições e vantagens. Algumas delas serão abordadas no decorrer desta tese.

Para introduzir o conceito de controlador ótimo, seja o modelo dinâmico discreto dado por

$$x(k+1) = f(x(k), u(k)) \quad (1)$$

em que  $x(k)$  representa os estados do sistema e  $u(k)$  as variáveis manipuladas, ambos no instante atual.

Como na melhor das hipóteses o modelo pode ser estimado (ainda que bem estimado sempre haverá discrepância entre o modelo e a realidade), a função  $f$  é desconhecida e substituída por um modelo aproximado. Sendo assim, dada uma determinada função custo que leva em conta os objetivos do controlador, o problema de otimização ótimo a ser resolvido pode ser definido como

$$\min_u \sum_{i=0}^{\infty} \ell(\hat{x}(i), u(i)) \quad (2a)$$

$$\text{s.a. } \hat{x}(i+1) = f(\hat{x}(i), u(i)), \quad \forall i \in \mathbb{I}_{[0, \infty]} \quad (2b)$$

$$\hat{x}(0) = x(k) \quad (2c)$$

$$\hat{x}(i) \in \mathcal{X}, \quad \forall i \in \mathbb{I}_{[0, \infty]} \quad (2d)$$

$$u(i) \in \mathcal{U}, \quad \forall i \in \mathbb{I}_{[0, \infty]} \quad (2e)$$

sendo  $\hat{x}(i)$  as predições dos estados,  $u(i)$  as ações de controle resultantes do problema de otimização,  $\mathcal{U}$  e  $\mathcal{X}$  os conjuntos de estados e ações de controle possíveis, respectivamente<sup>1</sup>.

Entretanto, o fato de que o horizonte de tempo infinito raramente é tratável em tempo computacional finito (por ter que calcular uma lei de controle para todo o horizonte  $u = \kappa(x)$ ), torna-se necessário encontrar outras maneiras de resolver o problema. Uma das técnicas bem aceitas pelas suas vantagens e versatilidade é Controlador Preditivo Baseado em Modelo, a ser detalhado na seguinte seção.

### 2.1 CONTROLADOR PREDITIVO BASEADO EM MODELO

O Controle Preditivo Baseado em Modelo (MPC) é uma família de técnicas de controle que faz uso de um modelo para prever o comportamento futuro do processo e, com base nessas predições, minimizar uma função de custo que pondera o erro de seguimento de referências e as

<sup>1</sup> Neste trabalho será utilizada a convenção de que os valores dos estados medidos serão representados pelo símbolo  $x(k)$  com  $k$  sendo o instante de tempo; os estados estimados serão representados com o símbolo  $\hat{x}(i)$ , sendo que o subíndice  $i$  denota o instante de predição.

ações de controle e considera um conjunto de restrições nas variáveis envolvidas (E. CAMACHO; C. BORDONS, 2007). A Figura 3 mostra o diagrama de blocos de um controlador MPC onde se observam o bloco do modelo encarregado do cálculo das predições e o bloco do otimizador, encarregado de calcular, a cada passo, a ação de controle.

A formalização dos chamados algoritmos de MPC surgiu na década de 1970 com alguns trabalhos que utilizavam predições baseadas em modelo para controlar processos industriais, tornando essa estratégia de controle rapidamente popular devido à simplicidade do algoritmo e ao uso de modelos de resposta ao impulso ou degrau utilizados que, embora possuam muito mais parâmetros do que as formulações no espaço de estado, geralmente são preferidos por serem mais intuitivos e exigirem menos informações a priori para a sua identificação (E. CAMACHO; C. BORDONS, 2007). Desta forma, as formulações clássicas dos controladores MPC utilizam modelos descritos em função de  $\Delta u$ , ou seja, do incremento da ação de controle durante o período de amostragem. Entretanto, existem vários controladores MPC na literatura, cada um modelando o sistema de uma forma e compondo a sua própria função custo a ser minimizada. Dentre esses estão: DMC, MAC, IDCOM, PFC e GPC<sup>2</sup>.

Alternativamente, o sistema pode ser modelado utilizando a técnica de espaço de estados, cuja formulação incremental utilizando o modelo de predição aumentado pode ser descrito por

$$\begin{bmatrix} \hat{x}(i+1) \\ u(i) \end{bmatrix} = \begin{bmatrix} A & B \\ 0 & I \end{bmatrix} \begin{bmatrix} \hat{x}(i) \\ u(i-1) \end{bmatrix} + \begin{bmatrix} B \\ I \end{bmatrix} \Delta u(i) \quad (3a)$$

$$\hat{y}(i) = \begin{bmatrix} C & 0 \end{bmatrix} \begin{bmatrix} \hat{x}(i) \\ u(i-1) \end{bmatrix} \quad (3b)$$

sendo  $A$ ,  $B$  e  $C$  as matrizes de dinâmica, de entrada e de saída da modelagem clássica em espaço de estados,  $\hat{x}(i)$  as predições dos estados,  $u(i)$  as ações de controle,  $\hat{y}(i)$  a saída do sistema e  $\Delta u(i) = u(i) - u(i-1)$ .

Para o modelo discreto da equação (1), o problema de otimização a ser resolvido pelo MPC pode ser definido como

$$\min_{\Delta u} J = \sum_{i=0}^{N-1} \|\hat{x}(i) - x^{sp}(i)\|_Q^2 + \sum_{j=0}^{N_u-1} \|\Delta u(j)\|_R^2 \quad (4a)$$

$$\text{s.a. } \hat{x}(i+1) = f(\hat{x}(i), u(j)), \quad \forall i, j \in \mathbb{I}_{[0, N-1]} \quad (4b)$$

$$\hat{x}(0) = x(k) \quad (4c)$$

$$\hat{x}(i) \in \mathcal{X}, \quad \forall i \in \mathbb{I}_{[0, N-1]} \quad (4d)$$

$$u(j) \in \mathcal{U}, \quad \forall j \in \mathbb{I}_{[0, N-1]} \quad (4e)$$

<sup>2</sup> No livro de E. Camacho e C. Bordons (2007) podem ser obtidos mais detalhes desses e outros controladores utilizados na indústria.

sendo  $J$  a função custo do MPC, chamada de custo de etapa,  $\hat{x}(i)$  as predições dos estados,  $x^{SP}(i)$  os valores de referência para os estados,  $\Delta u(j)$  os incrementos da ação de controle resultantes do problema de otimização,  $N$  o horizonte de predição,  $N_u$  o horizonte de controle e  $\mathcal{U}$  e  $\mathcal{X}$  os conjuntos de estados e ações de controle possíveis, respectivamente.

É importante destacar que o MPC soluciona um problema de otimização em *malha aberta* a cada período de amostragem, cujo resultado é, para o estado atual do sistema  $x(k)$ , uma sequência ótima de incrementos na ação de controle  $\Delta u = \{\Delta u(0), \Delta u(1), \Delta u(2) \dots \Delta u(N_u - 1)\}$ . Entretanto, o MPC aplica apenas o primeiro valor da variação da ação de controle  $\Delta u(0)$  ao sistema, utilizando a chamada estratégia de horizonte deslizante, resolvendo um novo problema de otimização a cada instante  $k$ . Portanto, o MPC substitui a necessidade do cálculo de uma lei de controle  $u = \kappa(x)$  calculada *off-line* pelo controlador ótimo 2 que exigiria um grande esforço computacional, pela solução de um problema de otimização em malha aberta *on-line*. Esta substituição é perfeitamente aplicável desde que a solução do problema de otimização possa ser obtida dentro do período de amostragem do sistema (MAYNE, David Q., 2014). Deve ser destacado que, no cálculo das predições, as condições iniciais utilizadas são atualizadas com o estado real da planta a cada período de amostragem. Esta estratégia de repetida solução do problema de otimização confere ao MPC, *implicitamente*, características de um sistema realimentado, podendo enfrentar eficientemente eventuais incertezas do sistema e perturbações (MESBAH, 2016).

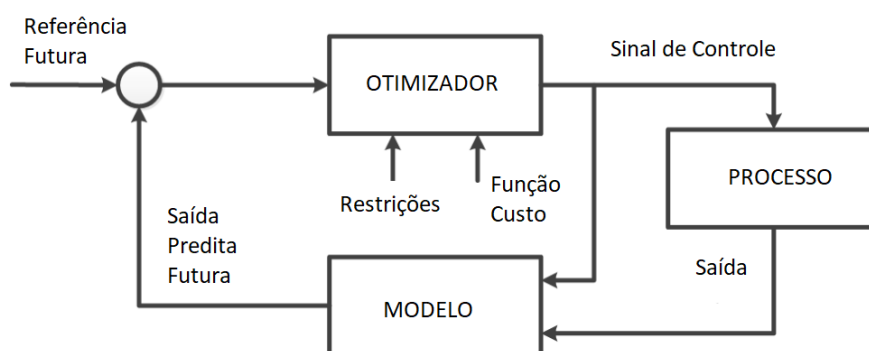


Figura 3 – Diagrama de blocos do algoritmo de um Controlador Preditivo Baseado em Modelo (MPC).

Fonte: (COSTA MENDES, 2016)

O controle preditivo baseado em modelo tem sido uma estratégia de controle com grande aceitação tanto na academia quanto na indústria por apresentar uma série de vantagens se comparado a alternativas de controle multivariável existentes. O MPC tem a capacidade de lidar com plantas mono e multivariáveis, inclui diretamente a realimentação e o controle *feedforward* na sua formulação e permite a compensação intrínseca de atrasos de transporte (NORMEY-RICO; CAMACHO, 2007). O *survey* de Qin e Badgwell (2003) descreve bem a dimensão da importância que as estratégias MPC alcançaram na indústria, comentando sobre as suas vantagens e habilidades frente ao controle de sistemas complexos sujeitos a



restrições. Uma prova disso é o fato do MPC ser a estratégia de controle avançado mais utilizada atualmente na indústria petroquímica e de processos (CAMPOS *et al.*, 2013).

Basicamente, a estratégia de controle MPC consiste em aplicar ao sistema, no instante atual, o primeiro valor da solução de controle de um problema de otimização com horizonte finito<sup>3</sup>. Por esse motivo, o problema de controle preditivo original não tinha garantia de estabilidade intrínseca. Versões mais atuais do MPC são projetadas com garantia de estabilidade através de ponderações na função custo e pelo aumento do horizonte de predição. Na prática, essa solução apresentava-se funcional, mas foi criticada por R. R. Bitmead *et al.* (1990) como sendo um “jogo” entre a tentativa de alcançar estabilidade e a modificação do problema de controle ótimo. Segundo David Q. Mayne (2014) a indústria não deu atenção ao problema da estabilidade até o ano 2000 quando D.Q. Mayne *et al.* (2000), baseados na teoria de Lyapunov, chegaram a um consenso sobre as condições que levavam à garantia da estabilidade nominal, sendo elas: a) o uso de uma restrição terminal como um invariante positivo possível do sistema<sup>4</sup> e b) o custo terminal seja uma função de Lyapunov<sup>5</sup> associada ao sistema. Na seção 2.3 será abordado o tema da estabilidade com mais detalhes.

(já aparece na seção de estabilidade) Sem a pretensão de fazer uma revisão histórica completa da evolução da garantia de estabilidade para MPC, elencam-se a seguir alguns trabalhos relevantes na área que marcaram tal evolução. No início da década de 90, os trabalhos de Mosca *et al.* (1990) e Clarke e Scattolini (1991) fazem menção à garantia de estabilidade em controladores MPC para sistemas lineares irrestritos alcançada através da imposição de *restrições terminais de igualdade*. Em contra partida, Michalska e D. Q. Mayne (1993) propõem a relaxação da restrição para uma *restrição de desigualdade*, formulando assim uma estratégia de controle para sistemas não lineares sujeitos a restrições que elege como região terminal um invariante positivo do sistema. Com esta abordagem, o trabalho de Michalska e D. Q. Mayne (1993) é considerado um marco para as futuras linhas de pesquisa no tema. Em outra direção, R. R. Bitmead *et al.* (1990) propõem, para alcançar a estabilidade em controle sistemas lineares irrestritos, a utilização de um *custo terminal* quadrático cuja matriz de ponderação é calculada pela solução da equação de Ricatti. Entretanto, a utilização conjunta da restrição terminal e do custo terminal é a estratégia mais presente nas formulações atuais do MPC. Vários autores, desde a década de 80, apresentam trabalhos utilizando ambas as estruturas, mas D.Q. Mayne *et al.* (2000) demonstram que todas as estratégias propostas até então atendem a determinadas condições gerais de estabilidade e estabelece que a utilização do custo terminal e da restrição terminal no controle preditivo pode garantir estabilidade assintótica para sistemas não lineares

<sup>3</sup> Utiliza-se horizonte finito por razões computacionais práticas relativas à dificuldade de solução de problemas de otimização complexos utilizando horizonte infinito.

<sup>4</sup> **Invariante Positivo:** Dado um sistema autônomo  $x(k+1) = f(x(k))$ , um conjunto  $\Omega$  é um invariante positivo do sistema se, dado um estado  $x(k) \in \Omega$  a solução do sistema permanece em  $\Omega$ , ou seja,  $f(x(k)) \in \Omega$ . Da mesma forma, para sistemas controlados  $x(k+1) = f(x(k), u(k))$  o conjunto  $\Omega$  é conjunto invariante positivo de controle, com  $u \in \mathcal{U}$ , se para todo  $x \in \Omega$  existe um  $u \in \mathcal{U}$  de tal modo que  $f(x(k), u(k)) \in \Omega$ .

<sup>5</sup> **Função de Lyapunov:** uma função contínua positiva definida  $V_f(\cdot)$  é uma função de Lyapunov se satisfizer a condição  $V_f(f(x, u)) - V_f(x) + \ell(x, u) \leq 0$ , com  $\ell(\cdot)$  também positiva definida.

sujeitos a restrições. Nesse mesmo trabalho os autores estabelecem que as condições suficientes para tal são que a restrição terminal seja um invariante positivo possível do sistema e o custo terminal seja uma função de Lyapunov associada ao sistema.

## 2.2 ESTRATÉGIAS MPC COM CRITÉRIO ECONÔMICO NA FORMULAÇÃO

Apesar da variedade de algoritmos MPC existentes, cada um propondo diferentes funções custo para compor a sua lei de controle, em geral, os controladores MPC atuam no desempenho do sistema através da minimização de uma função tipicamente quadrática que penaliza o desvio das saídas ( $y$ ) para uma referência ( $y^{ref}$ ) e o custo da variação da ação de controle ( $\Delta u$ ) (E. CAMACHO; C. BORDONS, 2007). Entretanto, no contexto das indústrias de processos a rentabilidade e a otimização em termos econômicos têm motivado o surgimento de várias abordagens incluindo critérios econômicos na sua formulação.

A Figura 4 mostra a hierarquia simplificada dos sistemas de automação industrial hierárquicos, sendo que na camada de planejamento definem-se os objetivos macro da empresa, como quantidade de vendas, estoque e produção, analisando um horizonte da ordem de meses. Devido à complexidade dos sistemas industriais, é comum que os modelos utilizados nesta camada de planejamento sejam simplificados e não considerem as dinâmicas da planta nem as perturbações, permitindo que algoritmos como programação linear (Programação Linear (LP)) e programação inteira mista (Programação Inteira Mista (MLP)) possam ser utilizados (CAMPOS *et al.*, 2013). Tipicamente, a camada de otimização em tempo real<sup>6</sup> (RTO) utiliza modelos não lineares complexos executados em tempos de amostragem grandes, na ordem de horas-dias. Entretanto, assim como na camada de planejamento, os modelos são, comumente, estáticos. Nesta camada, considera-se uma função objetivo econômica sujeita às restrições do sistema para a resolução do problema de otimização, sendo que as suas saídas são, normalmente, as referências (estados estacionários) para as variáveis controladas do sistema. A camada do controle avançado (MPC) é a responsável por estabelecer a melhor trajetória das variáveis manipuladas para atender aos requisitos impostos (referências) pela camada superior. Por último, a camada de instrumentação e controle regulatório implementa controladores, que se encarregam de manter as variáveis controladas nos valores requeridos pela camada anterior (ELLIS *et al.*, 2014).

Considerando disponíveis as informações dadas pela camada de planejamento, para um sistema descrito por  $x(k+1) = f(x(k), u(k))$ , o problema de otimização econômico resolvido

<sup>6</sup> Neste trabalho considera-se uma eventual abordagem de Programação da Produção como sendo parte da camada de RTO.



Figura 4 – Camadas dos sistemas de automação e controle industriais.  
Fonte: (CAMPOS *et al.*, 2013)

pela camada RTO é

$$(x^{sp}, u^{sp}) = \arg \min_u \ell(\hat{x}, u) \quad (5a)$$

$$F(\hat{x}, u) = 0, \quad (5b)$$

$$\hat{x} \in \mathcal{X}_p \quad (5c)$$

$$u \in \mathcal{U}_p \quad (5d)$$

sendo  $\ell(\hat{x}, u)$  a função econômica e  $\mathcal{X}_p$  e  $\mathcal{U}_p$  os conjuntos dos valores possíveis para os estados e o controle, respectivamente, definidos pela camada de planejamento. Considerando que o problema 5 possua solução e seja única, esta solução será composta pelos valores estacionários a serem tomados como referência pelo MPC  $(x^{sp}, u^{sp})$ .

Apesar da conveniência de dividir o problema de controle em camadas, esta abordagem hierárquica pode apresentar inconsistência entre a camada RTO e o MPC decorrente das discrepâncias entre os modelos utilizados em cada camada (ALAMO, Teodoro *et al.*, 2014) resultando, por exemplo, no eventual cálculo de estado estacionário pelo RTO que seja infactível para o modelo utilizado pelo MPC, além das diferentes escalas de tempo em que cada camada opera (períodos de amostragem).

Uma das maneiras de contornar esse problema é a utilização de uma camada intermediária entre o RTO e o MPC, chamada de *Steady State Target Optimizer* (SSTO), cuja função é, dada uma referência fornecida pelo RTO, calcular um ponto estacionário *factível* a ser repassado para o MPC. A camada intermediária SSTO minimiza, tipicamente, uma função custo quadrática que penaliza o erro para a referência fornecida pelo RTO (MUSKE, 1997), (RAO; RAWLINGS, James B., 1999) e (YING; JOSEPH, 1999).

Outra desvantagem da abordagem hierárquica tradicional é a falta de um critério econômico na camada MPC, que é quem trata do comportamento dinâmico do sistema. Ou seja, apesar do RTO levar em conta critérios econômicos para calcular os estados estacionários, não se é levada em conta qual seria a *trajetória* mais econômica a percorrer até chegar a eles, pois o MPC não tem informação econômica na sua formulação.

Nesse contexto, há vários trabalhos que propõem soluções para contornar os problemas econômicos decorrentes da discrepância entre os modelos do RTO e o MPC, dentre os quais estão:

- *Dynamic RTO (DRTO)*: Estratégia de controle cuja camada de RTO opera com algoritmos de otimização dinâmica, oferecendo não mais um estado estacionário para a camada inferior de MPC, mas uma trajetória que pode levar em conta critérios econômicos (KADAM; MARQUARDT, 2007), (BIEGLER, 2009), (WÜRTH *et al.*, 2009).
- *One-layer MPC*: Concebido inicialmente por Zanin *et al.* (2002), propõe fundir as camadas RTO e MPC em uma única camada, integrando os critérios econômicos do RTO ao problema de otimização do MPC através da adição de uma parcela econômica à função objetivo.
- *Economic MPC (EMPC)*: Esta formulação também é concebida com uma única camada de otimização, porém utiliza a própria função econômica do RTO como custo de etapa da função objetivo do MPC (AMRIT, 2011), (RAWLINGS, J. B. *et al.*, 2012a). Esta abordagem não considera levar o sistema a um determinado ponto estacionário e, ao invés disso, leva o sistema ao estacionário mais econômico.

A seguir, será feita uma breve apresentação de algumas das abordagens citadas.

### 2.2.1 Dynamic RTO (DRTO)

Herdando as características da estratégia de otimização hierárquica multi-camadas, o DRTO busca simplificar o problema geral de otimização em dois subproblemas. Segundo a nomenclatura utilizada por Kadam e Marquardt (2007)<sup>7</sup>, diferentemente de abordagens RTO tradicionais, o DRTO oferece como resultado final não mais um estado estacionário para a camada inferior de MPC, mas uma trajetória que pode levar em conta critérios econômicos. A Figura 5 (a) mostra uma abordagem de otimização dinâmica que não utiliza realimentação para atualizar o modelo. Nessa abordagem não há otimização *online*, ou seja, a camada superior calcula a trajetória ótima para as variáveis controladas e repassa essa informação a cada período de amostragem em que ela trabalha, tipicamente muito maior do que o período de amostragem da camada inferior. Esta abordagem é chamada de otimização dinâmica em malha aberta.

<sup>7</sup> Dado que formulações de DRTO são um tema recente de pesquisa, há divergências entre autores sobre a terminologia utilizada e sobre os fundamentos do tema. Nesta tese utiliza-se a terminologia definida por Kadam e Marquardt (2007).

Em contrapartida, a Figura 5 (b) mostra uma configuração em que a camada de otimização conta com a malha de realimentação e, conseqüentemente, otimização *online*. Esta abordagem tem a vantagem de poder recalculas as trajetórias econômicas ótimas lidando melhor com eventuais incertezas. Esta segunda abordagem é chamada de otimização dinâmica em malha fechada e, dependendo de como as incertezas afetam as trajetórias, uma ou outra estratégia pode ser implementada, levando em conta os requisitos do sistema a ser controlado (KADAM; MARQUARDT, 2007).

Como dito anteriormente, a utilização da otimização dinâmica, apesar de eficaz, pode ser um processo complexo nem sempre possível de se resolver com os recursos tecnológicos disponíveis (SOUZA *et al.*, 2010).

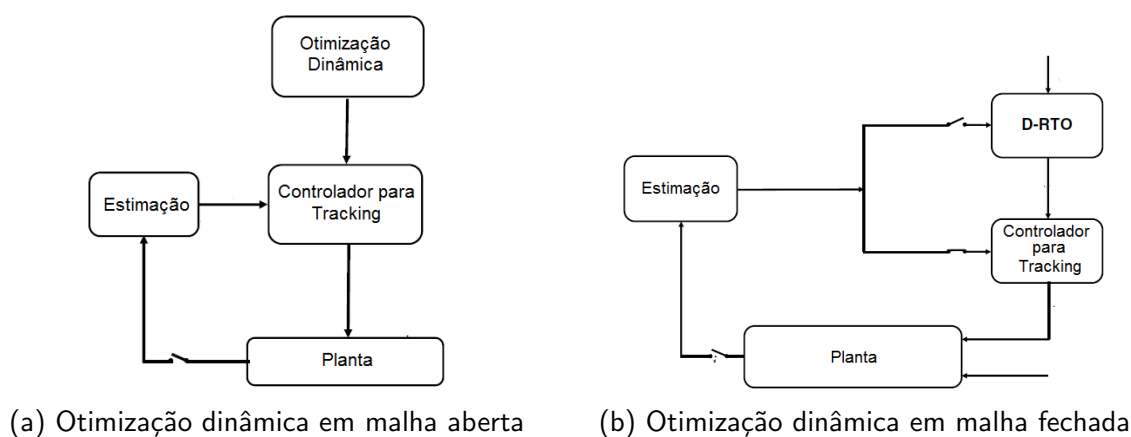


Figura 5 – Estratégia de controle DRTO.

### 2.2.2 One-layer MPC

O controlador chamado *One-layer* MPC propõe fundir as camadas RTO e MPC em uma única estrutura integrando os critérios econômicos ao problema de otimização do MPC. Zanin *et al.* (2002), buscando eliminar os inconvenientes resultantes da discrepância entre os modelos do RTO e MPC, propuseram a unificação das camadas através da adição de uma parcela econômica à função objetivo do controlador MPC. Os autores obtiveram excelentes resultados, entretanto, dependendo do sistema a ser controlado, a parcela econômica pode ser altamente não linear e complexa de resolver, dificultando a solução do problema de otimização. Nesse sentido, Souza *et al.* (2010) apresentaram uma proposta de controlador preditivo *one-layer* que utiliza, ao invés de uma função econômica complexa, apenas o seu gradiente, reduzindo consideravelmente o esforço computacional para a solução do problema de otimização. Mais tarde, Teodoro Alamo *et al.* (2014) estendem o trabalho de Souza *et al.* (2010) e propõem uma formulação *one-layer* baseada em gradiente com garantia de convergência ao objetivo econômico, apresentando algumas propriedades, das quais destacam-se:

- O algoritmo requer a solução de apenas um problema de otimização quadrática;

- Apresenta factibilidade para quaisquer mudanças do objetivo econômico;
- Garante convergência para o objetivo econômico;
- Oferece aumento do domínio de atração.

O controlador apresentado por Teodoro Alamo *et al.* (2014) é baseado no chamado MPC para *tracking*, originalmente proposto por Limon *et al.* (2008) e que será detalhado no decorrer desta tese.

### 2.2.3 Economic MPC (EMPC)

Como apresentado até aqui, as abordagens hierárquicas multi camada clássicas e as suas variações oferecem possibilidade de levar em conta critérios econômicos no problema de controle preditivo e têm sido amplamente utilizadas nas mais diversas aplicações. Entretanto, tem havido um aumento na quantidade de problemas com requisitos de desempenho econômicos em que a abordagem multicamadas apresenta-se ineficiente ou inapropriada (RAWLINGS, J. B. *et al.*, 2012b). Na abordagem do *One-Layer* MPC considera-se a integração do RTO ao MPC para contornar esse problema. Entretanto, a proposta do chamado *Economic Model Predictive Control* aponta em outro sentido que é o de utilizar a própria função econômica do RTO como custo de etapa da função objetivo do MPC. Portanto, o problema de otimização a ser resolvido pode ser escrito como

$$\min_u \sum_{i=0}^{N-1} \ell(\hat{x}(i), u(i)) \quad (6a)$$

$$\text{s.a. } \hat{x}(i+1) = f(\hat{x}(i), u(i)), \quad \forall i \in \mathbb{I}_{[0, N-1]} \quad (6b)$$

$$\hat{x}(0) = x(k) \quad (6c)$$

$$\hat{x}(i) \in \mathcal{X}, \quad u(i) \in \mathcal{U} \quad \forall i \in \mathbb{I}_{[0, N-1]} \quad (6d)$$

$$\hat{x}(N) = x^{SP} \quad (6e)$$

sendo que  $\ell(\hat{x}(i), u(i))$  representa a função econômica e  $\hat{x}(i)$  os estados preditos no instante  $i$ ;  $x^{SP}$  é o estado terminal do MPC Econômico (EMPC), ou seja, o *setpoint* dado pela camada de planejamento. Esta abordagem não considera apenas levar o sistema a um determinado ponto estacionário, mas considera *como* levar o sistema a esse ponto estacionário. Ou seja, o EMPC leva em conta a trajetória mais econômica, no sentido do critério determinado pela função  $\ell(\cdot)$ , para alcançar o estado estacionário dado pela camada de planejamento. Entretanto, é importante destacar que esta abordagem pode demandar grande esforço computacional para encontrar a solução do problema de otimização.

Note-se que o EMPC utiliza a ação de controle absoluta ( $u$ ) ao invés da incremental ( $\Delta u$ ). Esta é a formulação mais usual quando se quer formular um MPC com garantias de

estabilidade, pois para isso faz-se necessário estabelecer relações diretas com a ação de controle ( $u$ ), além de conhecer o estado completo do modelo no espaço de estados<sup>8</sup>. Porém, o problema de otimização, como está colocado em (6), não apresenta garantia de estabilidade nem de factibilidade. As condições suficientes para garantir a estabilidade e factibilidade em formulações MPC são apresentadas a seguir.

### 2.3 MPC - CONDIÇÕES DE ESTABILIDADE

Segundo David Q. Mayne (2014), apesar de compreensível, a literatura utilizada na indústria não se detinha ao problema da estabilidade dos sistemas de controle preditivo (MPC). Contudo, vários foram os autores que trilharam nesse caminho, dentre eles estão os trabalhos de Mosca *et al.* (1990) e Clarke e Scattolini (1991) que, no início da década de 90, fizeram menção à garantia de estabilidade em controladores MPC para sistemas lineares irrestritos alcançando-a através da imposição de *restrições terminais de igualdade*. Em contra partida, Michalska e D. Q. Mayne (1993) propõem a relaxação da restrição para uma *restrição de desigualdade*, formulando assim uma estratégia de controle para sistemas não lineares sujeitos a restrições elegendo como região terminal um invariante positivo do sistema. Com esta abordagem, o trabalho de Michalska e D. Q. Mayne (1993) é considerado um marco para as futuras linhas de pesquisa no tema. Em outra direção, R. R. Bitmead *et al.* (1990) propõem, para alcançar a estabilidade em controle sistemas lineares irrestritos, a utilização de um *custo terminal* quadrático cuja matriz de ponderação é calculada pela solução da equação de Ricatti.

Entretanto, a utilização conjunta da restrição terminal e do custo terminal é a estratégia mais presente nas formulações atuais do MPC. Vários autores, desde a década de 80, apresentam trabalhos utilizando ambas as estruturas, sendo que D.Q. Mayne *et al.* (2000) demonstram que todas as estratégias propostas até então atendem a determinadas condições gerais de estabilidade e estabelece que a utilização do custo terminal e da restrição terminal no controle preditivo pode garantir estabilidade assintótica para sistemas não lineares sujeitos a restrições. Nesse mesmo trabalho os autores estabelecem que as condições suficientes para tal são que a restrição terminal seja um invariante positivo possível do sistema e o custo terminal seja uma função de Lyapunov associada ao sistema.

A formulação apresentada por D.Q. Mayne *et al.* (2000), chamada de *formulação geral*

---

<sup>8</sup> Quando o estado não é completamente conhecido, há a necessidade de estimar os estados não mensuráveis.

do MPC, é dada pelo seguinte problema de otimização

$$\min_u \sum_{i=0}^{N-1} \ell(\hat{x}(i), u(i)) + V_f(x(N)) \quad (7a)$$

$$\text{s.a. } \hat{x}(i+1) = f(\hat{x}(i), u(i)), \quad \forall i \in \mathbb{I}_{[0, N-1]} \quad (7b)$$

$$\hat{x}(0) = x(k) \quad (7c)$$

$$\hat{x}(i) \in \mathcal{X}, \quad u(i) \in \mathcal{U} \quad \forall i \in \mathbb{I}_{[0, N-1]} \quad (7d)$$

$$\hat{x}(N) \in \mathcal{X}_f \quad (7e)$$

sendo  $\ell(\hat{x}(i), u(i))$  o custo de etapa e  $V_f(x(N))$  o custo terminal do problema de otimização;  $\hat{x}(N)$  e  $\mathcal{X}_f$  definidos como o estado terminal e a região terminal, respectivamente.

O conceito envolvido para se ter a garantia de estabilidade é assegurar que a solução do problema de otimização 7 decresça ao longo do horizonte.

Para poder estabelecer as condições suficientes de estabilidade assintótica, considere a seguinte hipótese (LIMON, Daniel, 2002):

**Hipótese 2.1** (Região terminal e custo terminal). *Seja um sistema tal que a) exista uma vizinhança da origem  $\Omega \subseteq \mathcal{X}$  sendo um conjunto invariante de controle do sistema<sup>9</sup>; e b) tenha associada uma função de Lyapunov de Controle<sup>10</sup>:  $V_f(x)$ , tal que*

$$\min_{u \in \mathcal{U}} \{V_f(f(x, u)) - V_f(x) + \ell(\hat{x}, u) \mid f(x, u) \in \Omega\} \leq 0. \quad (8)$$

Sendo assim, é possível estabelecer o seguinte teorema:

**Teorema 2.1** (Estabilidade assintótica). *(D.Q. Mayne et al. (2000))*

*Seja um problema de otimização MPC para um sistema  $x(k+1) = f(x(k), u(k))$ , tal que  $f(0, 0) = 0$ , que esteja sujeito às restrições  $x \in \mathcal{X}$ ,  $u \in \mathcal{U}$  e que tenha uma função de custo terminal e uma região terminal que satisfaçam a Hipótese 2.1. Então, o sistema controlado pela lei de controle  $u = \kappa_{\text{mpc}}(x)$  é assintoticamente estável com um domínio de atração  $X_N$  que é o conjunto de estados para os quais o problema de otimização é factível.*

Ou seja, para o problema de otimização (7), a estabilidade assintótica é garantida se  $V_f(x)$  for uma função de Lyapunov associada ao sistema e se a região terminal  $\mathcal{X}_f$  for um invariante positivo do sistema.

<sup>5</sup> **Conjunto invariante de controle:** Um conjunto  $\Omega \subset \mathbb{R}^n$  é dito ser invariante de controle associado a um sistema  $x(k+1) = f(x(k), u(k))$ , com  $x(k) \in \mathbb{R}^n$  e  $u(k) \in \mathbb{R}^m$ , se para todo  $x(0) \in \Omega$  existe uma lei de controle  $u = \kappa(x) \in \mathcal{U}$  tal que todo  $x(k) \in \Omega$ , com  $k \geq 0$ .

<sup>10</sup> **Função de Lyapunov de Controle:** Uma função  $V(x)$  é dita ser uma Função de Lyapunov de Controle associada a um sistema  $x(k+1) = f(x(k), u(k))$ , com  $x(k) \in \mathbb{R}^n$  e  $u(k) \in \mathbb{R}^m$ , se ela é definida positiva e satisfaz à condição de  $\Delta V(x) = \min\{V_f(f(x, u)) - V_f(x)\} \leq 0$ ,  $\forall x \in B_r$ , sendo  $B_r$  uma vizinhança da origem.



Outra forma de alcançar a estabilidade, principalmente em aplicações práticas, é aumentando o horizonte de predição, como é demonstrado no trabalho de Grüne e Pannek (2011). Segundo David Mayne (2016), o argumento utilizado para defender esta abordagem é que a maioria das aplicações práticas de controle não utiliza restrições terminais devido a eventuais dificuldades com a factibilidade do problema de otimização. Entretanto, se o problema de otimização original já faz uso de restrições “hard”<sup>11</sup> nos estados, a utilização de uma restrição terminal não implicará em problemas adicionais com respeito à infactibilidade se esta for um invariante positivo do sistema em malha fechada.

## 2.4 COMENTÁRIOS FINAIS DO CAPÍTULO

As formulações MPC discutidas até aqui consideram apenas o caso de sistemas determinísticos. Na prática, muitos dos processos reais, e principalmente no caso de sistemas de energia, estão sujeitos a incertezas que podem ser modeladas como variáveis estocásticas, mudando a abordagem do problema. Durante o decorrer desta tese serão discutidas as formulações de MPC para sistemas sujeitos a incertezas e as abordagens disponíveis para enfrentá-los.

---

<sup>11</sup> Ao invés das restrições “soft” que permitem eventual violação da restrição sob determinadas características, as restrições *hard* não permitem a violação da restrição em hipótese alguma.

### 3 MODELAGEM, CONTROLE E ANÁLISE DA EFICIÊNCIA DE CAMPOS SOLARES DE GRANDE PORTE

#### 3.1 INTRODUÇÃO

O uso de energia solar tem crescido significativamente nos últimos anos e vem sendo utilizada como fonte primária de energia em centrais heliotérmicas para processos como destilação, dessalinização, dentre outros (D. LIMA *et al.*, 2015). A expectativa é de que a energia elétrica heliotérmica atinja 11% da produção de energia elétrica mundial até 2050 (TECHNOLOGY. . . , 2014).

Em geral, a energia solar é captada utilizando dois sistemas: a) placas fotovoltaicas, que transformam diretamente a irradiação solar em energia elétrica; ou b) sistemas heliotérmicos, nos quais utiliza-se a irradiação solar para aquecer um determinado fluido de trabalho que irá produzir energia através do calor absorvido. O processo aqui estudado é o de um campo solar heliotérmico. Nestes sistemas, como a irradiação solar não pode ser controlada, o controle da temperatura é feito através da variação da vazão do fluido de trabalho. O campo, por sua vez, está sujeito a perturbações externas, como as variações da irradiação solar, seja pela posição do sol durante o dia ou por eventual passagem de nuvens, e à variação da temperatura ambiente e da temperatura do fluido que entra no campo solar. O objetivo de controle é manter, sempre que possível, a temperatura do fluido na saída do campo solar dentro da região de operação, mesmo quando sujeito às perturbações.

Particularmente, no caso de campos solares de grande porte, é comum que a irradiação solar alcance valores diferentes para cada setor do campo durante o dia, devido à passagem de nuvens localizadas, resultando em setores do campo com diferentes vazões e interconectados. Dessa forma, configura-se um problema maior e mais difícil de tratar, principalmente devido à dinâmica acoplada do arranjo dos campos sujeitos a diferentes perturbações. Neste capítulo exploram-se as características do funcionamento e as possibilidades de controle de campos solares de grande porte em diferentes topologias utilizando uma estratégia de Controle Preditivo baseado em Modelo (MPC).

O capítulo está organizado da seguinte forma: na seção 3.2 apresenta-se o processo estudado, na seção 3.3 comenta-se o tipo de controlador a ser utilizado, na seção 3.4 mostram-se os resultados e em seguida, na seção 3.5, os comentários finais.

#### 3.2 DESCRIÇÃO DO PROCESSO

O campo solar consiste em um sistema de captação da irradiação solar que transfere o calor absorvido para um fluido de trabalho. A modelagem do campo utilizada neste capítulo tem sido aplicada com bons resultados para concentradores parabólicos (C.M. CIRRE *et al.*, 2007; ROCA *et al.*, 2008) e captadores planos (M. PASAMONTES *et al.*, 2013). Particularmente, o processo a ser modelado neste capítulo é o de um campo solar cujo fluido de trabalho é a água, isto porque deseja-se poder comparar os resultados na planta solar experimental que

se está construindo nas dependências da UFSC e utiliza a água como fluido térmico. Apesar disso, é importante esclarecer que os resultados obtidos podem ser facilmente extrapolados para campos que utilizem outros tipos de fluidos e de coletores, como os concentradores parabólicos, que é o mais comum em campos maiores. O modelo do campo é dado por

$$\rho C_p A_a \dot{T}_{oF}(t) = \beta_I I(t) - \frac{H}{L_{eq}} (\bar{T}(t) - T_a(t)) - \frac{C_p}{\eta_{eq}} \dot{m}_F (t - d_c) \frac{T_{oF}(t) - T_{iF}(t)}{L_{eq}} \quad (9)$$

onde  $T_{oF}$  é a temperatura do fluido térmico (neste caso da água) na saída,  $I$  é a irradiação solar,  $\bar{T}$  é a temperatura média do coletor (que é dada pela média aritmética entre a temperatura de entrada e a de saída do coletor),  $T_a$  é a temperatura ambiente,  $\dot{m}_F$  é a vazão mássica da água,  $d_c$  é o atraso de transporte entre a entrada e a saída e  $T_{iF}$  é a temperatura de entrada da água. Os demais elementos são parâmetros do processo, cujos valores foram ajustados seguindo como referência o trabalho de (ROCA *et al.*, 2008) e estão representados na Tabela 1.

As variações na intensidade da irradiação solar durante o dia, a temperatura da água de entrada no campo solar e a temperatura ambiente são consideradas perturbações. As perturbações provenientes da irradiação solar são resultantes da variação da irradiação durante o dia e da passagem de nuvens acima do campo solar, que podem ser perturbações muito rápidas e de grande amplitude, diferentemente da temperatura ambiente cuja dinâmica é muito mais lenta. Por outro lado, a variação da temperatura da água de entrada no campo solar é decorrente de vários elementos, como da própria irradiação solar, da vazão da água, da temperatura ambiente e do consumo de energia térmica do sistema que utiliza a água quente.

Para otimizar a eficiência do coletor e evitar esforços internos por dilatação que danifiquem o conjunto, deve ser considerada uma restrição para a diferença de temperatura entre a entrada e saída do coletor (ROCA *et al.*, 2008). Para este trabalho será considerada a restrição

$$5 \text{ }^\circ\text{C} < [T_{oF}(t) - T_{iF}(t)] < 25 \text{ }^\circ\text{C} \quad (10)$$

onde  $T_{oF}$  é temperatura de saída e  $T_{iF}$  a temperatura de entrada do campo solar. Por outro lado, para manter o equilíbrio hidrodinâmico e evitar a cavitação da bomba, a vazão mássica é limitada em

$$1,2 \text{ kg/s} < \dot{m}_F < 4,8 \text{ kg/s}. \quad (11)$$

Para poder implementar o modelo em simulador, a Equação (9) foi discretizada utilizando uma aproximação *forward* (D. LIMA *et al.*, 2015). O modelo do campo solar é dado por

$$T_{oF}(k) = T_{oF}(k-1) + \frac{\beta_I T_s}{\rho C_p A_a} I(k-1) - \frac{H T_s}{L_{eq} \rho C_p A_a} (\bar{T}(k-1) - T_a(k-1)) - \frac{T_s}{\rho A_a \eta_{eq}} \dot{m}_F (k-1 - d_z) \frac{T_{oF}(k-1) - T_{iF}(k-1)}{L_{eq}}. \quad (12)$$

Tabela 1 – Parâmetros do processo

Símbolo	Descrição	Valor
$A_a$	Seção reta do absorvedor	$1,7453e^{-4} \text{ m}^2$
$C_p$	Calor específico da água	4190 J/kgK
$H$	Coeficiente de perdas térmicas	4 J/sK
$L_{eq}$	Comprimento equivalente do tubo absorvedor	5,67 m
$\beta_I$	Irradiância do modelo	0,1024 m
$\rho$	Densidade da água	975 kg/m <sup>3</sup>
$d_c$	Atraso de transporte no campo solar para este trabalho	50 s
$\eta_{eq}$	Parâmetro do processo	588

As variáveis do processo podem ser vistas na Tabela 2, sendo a temperatura da água de saída do campo solar  $T_{OF}$  a variável a ser controlada e a vazão da água que passa pelo campo solar  $\dot{m}_F$  a variável manipulada.

### 3.2.1 Modelagem de um campo solar de grande porte

Para simular o comportamento de um campo de grande porte, quatro<sup>1</sup> campos individuais foram arranjados em duas configurações diferentes, chamadas de Campos em Paralelo (CP) (Campos em Paralelo) e Campos em série (CS) (Campos em Série). Tanto no sistema CP quanto no CS a vazão total do arranjo é de quatro vezes a vazão de um campo individual e, portanto, o limite de operação da bomba de água para os arranjos é dado por

$$4,8 \text{ kg/s} < \dot{m}_A < 19,2 \text{ kg/s} \quad (13)$$

sendo  $\dot{m}_A$  a vazão resultante do arranjo<sup>2</sup>.

A configuração chamada de CP representa a conexão dos quatro campos em paralelo com válvulas proporcionais nas suas entradas e com saídas interconectadas, gerando um sistema com quatro entradas manipuladas, 12 perturbações ( $I$ ,  $T_a$  e  $T_{iF}$  para cada campo) e uma saída controlada, como pode ser visto na Figura 6. Nesta configuração, a vazão do arranjo é dada por

$$\dot{m}_A = \sum_{i=1}^4 \dot{m}_{Fi} \quad (14)$$

sendo  $\dot{m}_A$  a vazão resultante do arranjo e  $\dot{m}_{Fi}$ , com  $i = 1, 2, 3$  e  $4$ , as vazões individuais de cada campo. Uma característica importante desta configuração é que, a rigor, os campos individuais podem operar com vazões reduzidas, desde que a soma das vazões de cada campo esteja dentro dos limites de operação da bomba (13).

<sup>1</sup> Número escolhido arbitrariamente para obter um campo resultante de 2x2 campos originais e equidistantes.

<sup>2</sup> Foi utilizado o mesmo limite de operação de  $\dot{m}_A$  para ambos os arranjos com o intuito de equiparar as quantidades de calor disponibilizadas.

A temperatura de saída do arranjo é aproximada<sup>3</sup> por

$$T_{oA} = \frac{\sum_{i=1}^4 T_{oFi} \dot{m}_i}{\dot{m}_A} \quad (15)$$

sendo  $T_{oA}$  a temperatura resultante do arranjo dos campos solares,  $T_{oFi}$  e  $\dot{m}_i$ , com  $i = 1, 2, 3$  e  $4$ , as temperaturas de saída e as vazões mássicas de cada campo e  $\dot{m}_A$  a vazão resultante do arranjo.

Outra característica da configuração CP é que a temperatura de saída do arranjo é afetada instantaneamente pela alteração de vazão de qualquer um dos campos que a compõe, resultando em um sistema sem atraso de transporte e com dinâmica sensivelmente diferente à de um campo individual.

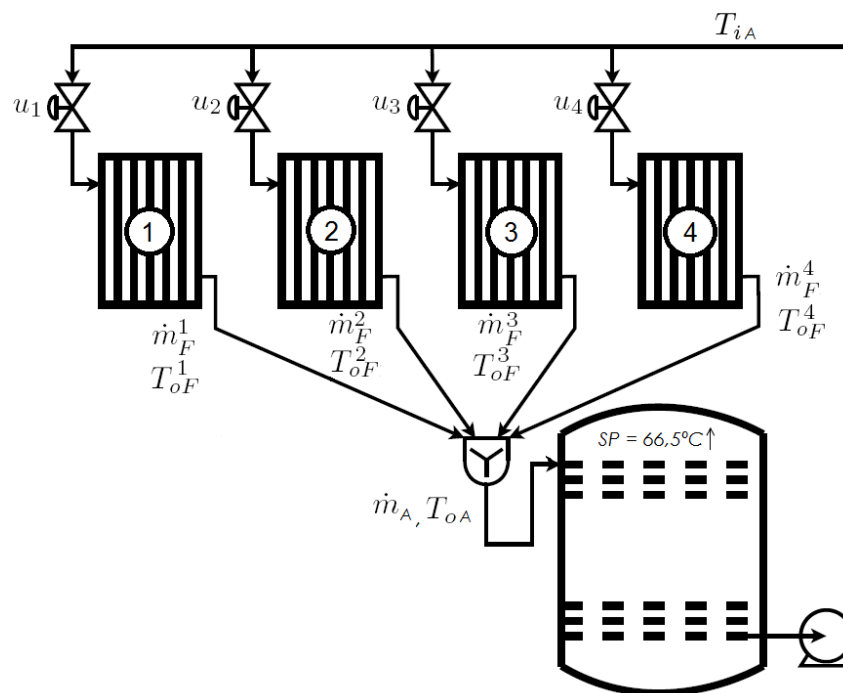


Figura 6 – Arranjo dos campos solares na configuração CP

Na outra configuração (CS) os campos estão conectados em série e a saída de um campo alimenta a entrada do outro, gerando um sistema com uma entrada manipulada, 12 perturbações ( $I$ ,  $T_a$  e  $T_{iF}$  para cada campo) e uma saída controlada, como pode ser visto na Figura 7. Para poder comparar os arranjos CP e CS em termos de eficiência energética, foi admitido que os campos solares são dimensionados para suportar a pressão hidráulica característica de cada arranjo.

<sup>3</sup> Por simplicidade, o modelo desconsidera a dinâmica da mistura.




Figura 7 – Arranjo dos campos solares na configuração CS

Tabela 2 – Variáveis do processo

Simbolo	Descrição	Unidade
$T_{oF}$	Temperatura de saída do campo solar	°C
$T_{oA}$	Temperatura de saída do arranjo	°C
$\dot{m}_F$	Fluxo mássico no interior do campo solar	kg/s
$\dot{m}_A$	Fluxo mássico do arranjo	kg/s
$I$	Irradiação solar	W/m <sup>2</sup>
$T_{iF}$	Temperatura de entrada do campo solar	°C
$T_{iA}$	Temperatura de entrada do arranjo	°C
$T_a$	Temperatura ambiente	°C

### 3.3 CONTROLE PREDITIVO PNMPC

Diversas são as maneiras de enfrentar o desafio de controlar uma planta não linear. Como visto no capítulo 2, a planta a ser controlada pelo MPC pode ser uma planta não linear. O que acontece é que, em muitos casos, recorre-se a técnicas de linearização para a obtenção de um modelo simplificado. Em boa parte dos casos este procedimento é aceitável, seja porque a planta opera em um ponto muito próximo da linearização ou porque o processo seja "pouco não linear". Entretanto, no sentido de explorar técnicas dedicadas ao controle de sistemas não lineares, decidiu-se por utilizar um controlador MPC chamado de *Practical Non-Linear Model Predictive Control* (*Practical Nonlinear Model Predictive Control* (PNMPC))(PLUCÊNIO, 2010).

Para o problema dos campos solares proposto neste capítulo, projetou-se a função custo

dada por

$$\begin{aligned}
 J = & \sum_{j=1}^N \eta_y [\hat{y}(k+j|k) - w(k+j)]^2 \\
 & + \sum_{i=1}^{N_{in}} \sum_{j=1}^{N_u} \eta_{\Delta u} [\Delta u_i(k+j-1)]^2 \\
 & + \sum_{j=1}^{N_u} \eta_u [u(k+j-1) - w_u(k+j-1)]^2 \\
 & + \eta_{r1} \sum_{i=1}^{N_{in}} \sum_{j=1}^N \eta_{r2} [\hat{y}_i(k+j|k) - w_i(k+j)]^2
 \end{aligned} \tag{16}$$

sendo que  $\eta_y$ ,  $\eta_{\Delta u}$ ,  $\eta_u$  e  $\eta_{r2}$  são as ponderações das parcelas de  $J$  para seguimento de referência da temperatura do arranjo, penalização da variação do controle, maximização da vazão do sistema e manutenção da temperatura de saída dos campos dentro dos limites de operação, respectivamente. Ainda,  $N$  é o horizonte de predição,  $N_u$  é o horizonte de controle,  $N_{in}$  é o número de entradas no arranjo ( $N_{in} = 4$  para o caso CP e  $N_{in} = 1$  para CS),  $\hat{y}$  é a temperatura de saída do arranjo predita,  $w$  é a referência da temperatura de saída do arranjo do sistema,  $\Delta u_i$  são os incrementos de vazão em cada campo (variáveis manipuladas),  $u$  é a vazão total do arranjo,  $w_u$  é a referência para a vazão total do arranjo (que corresponde ao máximo de vazão possível do sistema) e  $\hat{y}_i$  e  $w_i$  são a temperatura predita e a referência para a saída de cada campo, com  $\eta_{r1} = 1$  para o arranjo CP e  $\eta_{r1} = 0$  para o arranjo CS. O problema de otimização resume-se à minimização da função custo sujeita às restrições de vazão (11) (13). Como foi dito anteriormente, a referência de vazão é o máximo de vazão possível para o sistema, de forma que o resultado obtido com a utilização dessa função custo é o de, ainda que mantendo um *setpoint* de temperatura, maximizar a produção de energia do sistema.

A função custo (16) requer o cálculo das saídas preditas do sistema que podem ser calculadas como função das variáveis de decisão  $\Delta u$  conhecendo o modelo do processo. Porém, para que o problema de otimização resultante seja um problema de programação quadrática (QP), o modelo (9) não pode ser utilizado diretamente, dado que o modelo não linear das predições transformaria o problema de otimização em um problema de otimização não linear. Para evitar uma relação não linear entre as predições e as variáveis manipuladas, o PNMPC calcula as predições  $\hat{Y}$  através do modelo

$$\hat{Y} = G\Delta u + f \tag{17}$$

onde  $\Delta u$  é o vetor de incrementos de controle futuro,  $f$  representa a resposta livre do sistema e  $G$  é uma matriz que relaciona, de forma linear, os controles futuros e as saídas preditas<sup>4</sup>.

No caso do algoritmo PNMPC, a resposta livre  $f$  e a matriz  $G$  são calculadas por

$$f = f(\overleftarrow{y}, \overleftarrow{u}) \tag{18}$$

<sup>4</sup>  $G$  é calculada de maneira diferente para cada tipo de estratégia de MPC.

$$G = \frac{\partial \hat{Y}}{\partial \Delta u} \quad (19)$$

sendo que  $f$  é composta pelos valores passados da variável controlada  $\overleftarrow{y}$  e da variável manipulada  $\overleftarrow{u}$  e  $G$  é o jacobiano de  $\hat{Y}$  com relação aos incrementos de controle, sendo ela uma matriz dinâmica generalizada que pode ser utilizada para sistemas lineares e para sistemas não lineares contínuos e diferenciáveis (PLUCÊNIO, 2010). Com esta forma de cálculo de  $G$  o problema de otimização que se resolve a cada passo é igual ao dos algoritmos clássicos de controle MPC usados na indústria, como DMC ou GPC.

Dado que o valor das perturbações ( $I$ ,  $T_a$  e  $T_{iF}$ ) podem ser medidas, o modelo do sistema pode incluir estas medições para minimizar o erro de predição devido às perturbações. Portanto, a saída ( $Y$ ) do modelo completo da planta solar utilizado como modelo para o controlador é composto por três partes: a) o valor decorrente da ação de controle  $u$ , b) o valor decorrente das medições das perturbações (Ação *Feedforward*<sup>5</sup>) e c)  $f$ , o valor da resposta livre do sistema, resultando no modelo

$$\hat{Y} = G_u \Delta u + \underbrace{G_I \Delta I + G_{T_a} \Delta T_a + G_{T_{iF}} \Delta T_{iF}}_{\text{Feedforward}} + f \quad (20)$$

com as parcelas  $G_I \Delta I$ ,  $G_{T_a} \Delta T_a$  e  $G_{T_{iF}} \Delta T_{iF}$  compondo a ação *Feedforward* das perturbações  $I$ ,  $T_a$  e  $T_{iF}$ , respectivamente, sendo que os valores futuros das perturbações (no horizonte de predição do controlador) são considerados constantes e iguais aos valores atuais, ou seja, no instante  $k$ .

### 3.4 RESULTADOS

Para comparar o desempenho dos arranjos CS e CP, ambos foram submetidos às mesmas condições de irradiação<sup>6</sup>, temperatura ambiente e temperatura da água de entrada, considerando perfis de 5 horas de duração. Os perfis de irradiação podem ser vistos na Figura 8 e as temperaturas de entrada e ambiente na Figura 9. Observa-se na Figura 8 que os setores do campo serão diferentemente irradiados, especialmente devido à passagem de nuvens localizadas. É importante ressaltar que este fenômeno afeta aos setores do campo de forma diferente, resultando em um desequilíbrio térmico no sistema

O comportamento da temperatura e da vazão de saída de cada arranjo com referência de temperatura em 70 °C pode ser visto nas Figuras 10 e 11, onde nota-se que as dinâmicas de ambos os arranjos são parecidas.

Na configuração CS a vazão mínima nos campos é determinada pela vazão mínima da bomba. Se a irradiação cair a níveis muito baixos, ainda que a vazão seja reduzida ao valor mínimo, existe a possibilidade de que um ou mais campos solares não sejam capazes de elevar

<sup>5</sup> Também conhecido como controle antecipatório ou método da alimentação direta

<sup>6</sup> Apesar de não comporem um cenário real, foram escolhidos perfis de irradiação de diferentes épocas do ano e com muita variação para testar o controlador em casos extremos.






Figura 8 – Primeiro cenário de irradiações para os diferentes campos<sup>5</sup>




Figura 9 – Temperatura da água de entrada e ambiente aplicada aos campos solares

a temperatura da água que recebem ou, até mesmo, diminuí-la devido às perdas térmicas para o ambiente. A despeito disso, a configuração CP permite desativar campos<sup>7</sup> cuja irradiação for insuficiente para manter a temperatura da água de saída do campo dentro dos limites de operação (10), desde que seja atendida a restrição de vazão do arranjo (13).

Para analisar o comportamento dos arranjos em uma situação mais crítica, cenários com irradiações reduzidas foram utilizados, sendo estes 90%, 80%, 70% e 60% da irradiação do primeiro cenário, mantendo os diferentes perfis de irradiação para cada campo. Para quantificar a eficiência do sistema foi analisada a quantidade de calor disponibilizada pelo arranjo e a vazão total resultante.

<sup>7</sup> Neste trabalho, o campo é desativado quando a temperatura de saída permanecer menor ou igual à de entrada por um período maior do que um minuto.

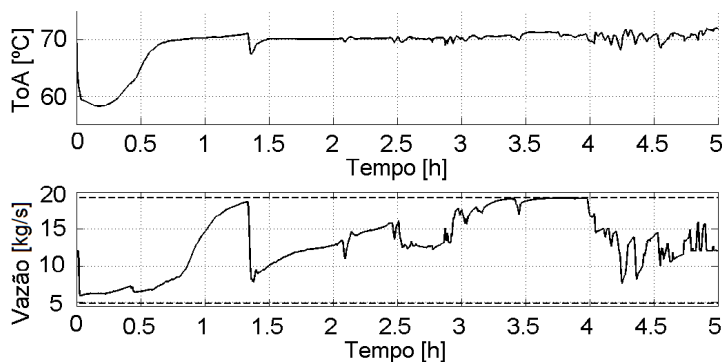


Figura 10 – Temperatura de saída e vazão do arranjo na configuração CP




Figura 11 – Temperatura de saída e vazão do arranjo na configuração CS

Além disso, foram calculados, para o tempo de simulação, os índices de desempenho médios entre os cenários Variação Total da Ação de Controle (*Total Variation*) (TV)(*Total Variation*) e Erro Médio Quadrático (*Integral Square Error*) (ISE)(*Integral Square Error*) para analisar o esforço de controle e o seguimento à referência, respectivamente, como pode ser visto na Tabela 3.




Figura 12 – Temperatura e vazão do arranjo na configuração CP com a possibilidade de desativação de campos sob irradiação reduzida 70%

Para ilustrar a evolução da vazão no caso de irradiações reduzidas, a Figura 12 mostra o comportamento do arranjo CP submetido a 70% da irradiação do primeiro cenário e com a possibilidade de desativar campos, onde nota-se que o controlador reduz a vazão do arranjo




Figura 13 – Vazão dos campos na configuração CP com a possibilidade de desativação de campos sob irradiação reduzida 70%

Tabela 3 – Volume de água e calor disponibilizados pelos arranjos CP e CS

Irradiação	Descrição	CS	CP	CP <sup>1</sup>	Diferença <sup>2</sup>	Diferença <sup>1,2</sup>
100%	Água[t]	227,4	231,8	229,2	1,9%	0,8%
	Calor[MJ]	10713,9	10822,4	10896,7	1,0%	1,7%
90%	Água[t]	193,3	201,5	200,5	4,2%	3,8%
	Calor[MJ]	8868,6	9005,3	9117,1	1,5%	2,8%
80%	Água[t]	157,3	167,0	167,0	6,1%	6,1%
	Calor[MJ]	7039,0	7158,9	7339,5	1,7%	4,3%
70%	Água[t]	123,8	133,3	133,9	7,7%	8,1%
	Calor[MJ]	5237,7	5306,0	5592,8	1,3%	6,8%
60%	Água[t]	103,4	106,6	106,3	3,1%	2,8%
	Calor[MJ]	3517,9	3579,7	3913,1	1,8%	11,2%
TV/ISE <sup>3</sup>	-	60,47/1,736e7	37,63/1,735e7	42,85/1,734e7	-	-

<sup>1</sup>Arranjo CP com possibilidade de desativar campos.

<sup>2</sup>Diferença do arranjo CP em relação ao arranjo CS.

<sup>3</sup>Índices de desempenho (média entre cenários):  $TV = \sum |\Delta \dot{m}(k)|$ ;  $ISE = \sum [w(k) - y(k)]^2$ .

para manter a temperatura de saída próxima à da referência; e a Figura 13 mostra a evolução das vazões nos campos separadamente.

A Figura 14 mostra o aumento de calor disponibilizado pelo arranjo CP, em relação ao arranjo CS, para cenários com 100%, 90%, 80%, 70% e 60% da irradiação original. O arranjo CP produz mais energia para todos os cenários, chegando a disponibilizar 1,8% mais calor no cenário 60% em relação ao arranjo CS. O arranjo CP com a possibilidade de desativação de campos apresentou a maior eficiência, chegando a gerar 11,2% mais calor no cenário 60%, se comparado com o arranjo CS. Por outro lado, apesar do valor do erro quadrático médio (ISE) de ambos os arranjos serem semelhantes, o esforço de controle no arranjo CP apresentou menor variação total (TV).

O aumento da eficiência do arranjo CP é devido a dois fatores: a) por deixar de transportar água que esteja abaixo da temperatura da água de entrada através da desativação do campo e b) pelas diferentes quantidades de calor perdidas para o ambiente em cada arranjo. Percebe-se, através do modelo do processo (9), que as perdas para o ambiente serão menores enquanto menor for a temperatura média do coletor, situação que o controlador do arranjo CP com possibilidade de desativação de campos enfrenta com mais facilidade. Na Figura 15 mostra-se a evolução das temperaturas dos campos no cenário 70%, onde nota-se que o arranjo com possibilidade de desativação de campos opera com temperaturas iguais ou menores, resultando em menores perdas para o ambiente, justificando a sua alta eficiência.

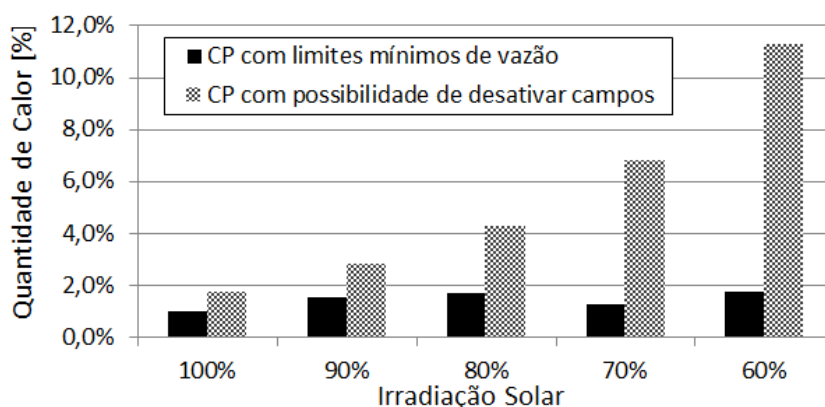


Figura 14 – Aumento da quantidade de calor absorvido no arranjo CP, em comparação ao CS, para diferentes irradiações

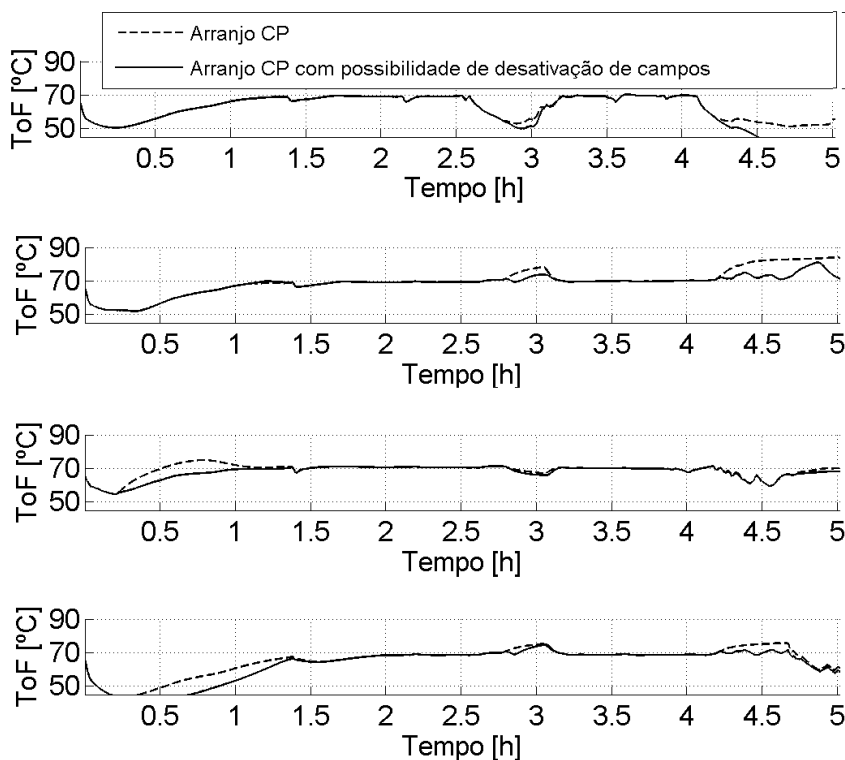


Figura 15 – Temperatura dos campos na configuração CP sob irradiação reduzida 70%

### 3.5 COMENTÁRIOS FINAIS DO CAPÍTULO

Este capítulo propôs-se a analisar e comparar o desempenho de campos solares de grande porte, utilizando a abordagem do PNMPC, em duas configurações diferentes: série (CS) e paralelo (CP). Apesar de oferecer volume total de água geralmente menor, a configuração em paralelo disponibiliza mais quantidade de calor em todos os cenários, alcançando eficiência 11,2% maior quando submetido a 60% da irradiação do primeiro cenário. Tal eficiência deve-se à possibilidade de desativar campos com eventual irradiação insuficiente e pelo fato do controlador permitir que os campos operem com temperaturas menores resultando em menores perdas de calor para o ambiente. Este resultado indica que a configuração em paralelo pode ser mais vantajosa em aplicações reais onde haja grande incidência de nuvens, que é o caso mais comum no Brasil.

Uma das contribuições desta tese é, portanto, ajudar a compreender melhor os efeitos práticos das diferenças entre as configurações que utilizam recirculação em paralelo e em série. Além disso, ainda que esteja fora do escopo deste trabalho, é importante dizer que um estudo mais aprofundado poderia ser feito para analisar a viabilidade econômica do sistema em paralelo levando em conta elementos como o investimento inicial (custo da aquisição de mais válvulas, etc) considerando o tempo útil da planta.

É importante destacar que, apesar de haver vários trabalhos acadêmicos que exploram a aplicação de controladores preditivos em sistemas heliotérmicos, a análise feita neste trabalho é relevante, principalmente porque não há informações claras sobre quais estratégias de controle são utilizadas pelos fabricantes de sistemas heliotérmicos vendidos comercialmente.

O próximo capítulo desta tese considera a configuração em paralelo de campos a mais vantajosa no que tange à absorção de calor e será usada para o estudo do efeito das perturbações estocásticas no sistema.

## 4 MODELAGEM ESTOCÁSTICA PARA O PROBLEMA DE CAMPOS SOLARES DE GRANDE PORTE

### 4.1 INTRODUÇÃO

Como comentado no capítulo 3, em campos solares de grande porte é comum que a irradiação solar alcance valores diferentes para cada setor do campo durante o dia devido à passagem de nuvens localizadas. Esta situação configura um problema difícil de tratar devido à característica estocástica da irradiação solar, cuja variação pode ser muito rápida e de grande amplitude e à dinâmica acoplada dos setores do campo sujeitos a diferentes perturbações, já que, ao existir a recirculação do fluído, o efeito das perturbações na temperatura de saída de cada setor do campo pode afetar a temperatura de entrada dos demais setores do campo, configurando a interdependência entre eles.

Por outro lado, a presença de variáveis estocásticas em problemas envolvendo controle preditivo baseado em modelo pode resultar, dentre outras coisas, em dificuldades para atender às restrições nas variáveis de saída e/ou estados do processo, uma vez que as incertezas ocasionam previsões também incertas. Para minimizar esse problema é possível incorporar as incertezas ao modelo e reescrever as restrições de forma probabilística, melhorando a robustez do MPC (SCHWARM, Alexander T.; NIKOLAOU, 1999a).

### 4.2 FUNDAMENTAÇÃO TEÓRICA

Em problemas de controle MPC é possível incluir a ação *feedforward* (Ação *Feedforward* (FF)) na formulação do controlador. Dentre as possibilidades de implementação da ação FF está o caso hipotético de conhecer a perturbação futura, de tal forma que o controlador, ao levar essa informação em conta, mantenha a saída do processo imune às perturbações. Entretanto, para um caso real, as perturbações futuras podem, no melhor dos casos, ser estimadas e, portanto, resultar em erro nas previsões do controlador. Este problema pode ser minimizado se houver algum conhecimento prévio das características das perturbações e este for incluído ao modelo, permitindo que uma restrição do tipo

$$y_{min} \leq \hat{y}(k+n|k) \leq y_{max} \quad ; \quad n = 1 \dots N \quad (21)$$

possa ser reescrita como uma restrição probabilística

$$\Pr \{y_{min} \leq \hat{y}(k+n|k) \leq y_{max}\} \geq (1 - \delta) \quad ; \quad n = 1 \dots N \quad (22)$$

sendo  $N$  o horizonte de previsão,  $\hat{y}(k+n|k)$  a previsão do instante  $n$  calculada no instante  $k$  com o modelo da incerteza incorporado e  $\delta$  representa o risco de violação da restrição.

A abordagem de restrições probabilísticas (Restrições Probabilísticas (*Chance Constraints*) (CC)) permite estabelecer o risco de violação da restrição original desde que o comportamento estocástico das perturbações possa ser modelado por uma Função Densidade de

Probabilidade (Função Densidade de Probabilidade (PDF)) de uma variável aleatória e esta informação seja inserida no modelo de predição<sup>1</sup>.

A função densidade de probabilidade de uma variável aleatória é uma função que descreve a probabilidade relativa dessa variável assumir um determinado valor. Por outro lado, a probabilidade da variável aleatória assumir um valor menor ou igual a um determinado valor é dada pela integral da PDF e denomina-se Função Densidade Acumulada (Função de Probabilidade Acumulada (CDF)) ou quantil (PINHEIRO *et al.*, 2012). A Figura (16) mostra a PDF e a CDF de uma variável aleatória gaussiana (ou normal) padronizada<sup>2</sup>.




Figura 16 – Função Densidade de Probabilidade e Densidade de Probabilidade Acumulada padrão. Adaptado de (PINHEIRO *et al.*, 2012)

Na próxima seção será demonstrado como pode ser inserida uma informação probabilística de uma perturbação no modelo do sistema.

#### 4.2.1 Modelagem Probabilística de uma Perturbação ao Sistema

Seja a variável  $q$  a representação de uma perturbação em um sistema qualquer. Como já foi dito, deseja-se modelar a perturbação de forma probabilística e, para isso,  $q$  pode ser separada em

$$q = \underbrace{q_d}_{\text{parcela determinística}} + \underbrace{q_e}_{\text{parcela estocástica}} \quad (23)$$

sendo  $q_d$  a parte conhecida (estimada ou histórica) e  $q_e$  a parte da incerteza que pode ser aproximada por uma Função Densidade de Probabilidade com parâmetros conhecidos,

<sup>1</sup> Como a modelagem da incerteza é inexata por definição, poderá ocorrer infactibilidade do problema de otimização restrito, caso que pode ser contornado com a utilização de variáveis de folga (*soft constraints*) (SCHWARM, Alexander T.; NIKOLAOU, 1999a).

<sup>2</sup> A forma padronizada (ou reduzida) de uma variável normal obtém-se subtraindo-se a média da variável original dividindo o resultado pelo desvio padrão original (PINHEIRO *et al.*, 2012).

comumente através de uma variável aleatória gaussiana. No contexto deste trabalho deve-se destacar que é comum modelar incertezas de fenômenos naturais como aproximações de ruídos gaussianos, permitindo utilizar a PDF de uma variável gaussiana como o modelo probabilístico de uma variável aleatória.

Por outro lado, é importante salientar que muitos dos fenômenos meteorológicos são autocorrelacionados<sup>3</sup>, o que permite fazer estimações de  $q_d$ .

#### 4.2.2 Inclusão da Incerteza no Modelo de um Sistema

Seja o modelo incremental

$$y(k+1) = \alpha y(k) + \beta \Delta u(k) + \gamma \Delta q(k) \quad (24)$$

com  $y$  sendo a variável controlada,  $\Delta u$  o incremento da variável manipulada,  $\Delta q$  o incremento da perturbação e  $\alpha$ ,  $\beta$  e  $\gamma$  coeficientes do modelo. Note-se que, para o exemplo tomado como modelo de predição (24), as predições dependem apenas dos valores anteriores da ação de controle e das perturbações. Por tanto, sem prejuízo do entendimento, para um horizonte de predição  $N$  teremos tanto o horizonte de predição das perturbações quanto o horizonte de controle limitados a  $N-1$ . Evidentemente que a demonstração a seguir pode ser estendida para o caso de que a predição dependa dos valores atuais do controle e das perturbações.

Portanto, as predições da variável controlada podem ser calculadas desenvolvendo o modelo recursivamente, de tal forma que, para o instante  $(k+2)$ , tem-se

$$\begin{aligned} \hat{y}(k+2|k) &= \alpha y(k+1) + \beta \Delta u(k+1) + \gamma \Delta q(k+1) \\ \hat{y}(k+2|k) &= \alpha(\alpha y(k) + \beta \Delta u(k) + \gamma \Delta q(k)) + \beta \Delta u(k+1) + \gamma \Delta q(k+1) \\ \hat{y}(k+2|k) &= \alpha^2 y(k) + \alpha \beta \Delta u(k) + \alpha \gamma \Delta q(k) + \beta \Delta u(k+1) + \gamma \Delta q(k+1) \end{aligned}$$

resultando em

$$\hat{y}(k+2|k) = \alpha^2 y(k) + \alpha \beta \Delta u(k) + \beta \Delta u(k+1) + \alpha \gamma \Delta q(k) + \gamma \Delta q(k+1). \quad (25)$$

Para o instante  $(k+3)$ , tem-se

$$\begin{aligned} \hat{y}(k+3|k) &= \alpha y(k+2) + \beta \Delta u(k+2) + \gamma \Delta q(k+2) \\ \hat{y}(k+3|k) &= \alpha^3 y(k) + \alpha^2 \beta \Delta u(k) + \alpha \beta \Delta u(k+1) + \alpha^2 \gamma \Delta q(k) + \alpha \gamma \Delta q(k+1) \\ &\quad + \beta \Delta u(k+2) + \gamma \Delta q(k+2) \end{aligned}$$

resultando em

$$\begin{aligned} \hat{y}(k+3|k) &= \alpha^3 y(k) + \alpha^2 \beta \Delta u(k) + \alpha \beta \Delta u(k+1) + \beta \Delta u(k+2) + \alpha^2 \gamma \Delta q(k) \\ &\quad + \alpha \gamma \Delta q(k+1) + \gamma \Delta q(k+2). \end{aligned} \quad (26)$$

<sup>3</sup> A autocorrelação é definida como a correlação entre membros de uma mesma série de observações ordenadas segundo um critério temporal ou espacial (KENDALL *et al.*, 1971). Uma das causas da autocorrelação de um sinal é a inércia que o sistema possui (YAFFEE; MCGEE, 2000; DAMODAR GUJARATI, 2008) de forma que o valor da variável em um determinado instante também depende de valores anteriores.



ou na forma matricial, separando a incerteza  $\Delta q$  em  $\Delta q_d$  e  $\Delta q_e$  com horizonte de predição  $N$  e horizonte de controle  $N_U = N - 1$  (considerando o horizonte de predição das perturbações =  $N - 1$ ), tem-se

$$\begin{aligned}
 \begin{bmatrix} \hat{y}(k+1|k) \\ \hat{y}(k+2|k) \\ \hat{y}(k+3|k) \\ \vdots \\ \hat{y}(k+N|k) \end{bmatrix} &= \underbrace{\begin{bmatrix} \beta & 0 & 0 & \dots & 0 \\ \alpha\beta & \beta & 0 & \dots & 0 \\ \alpha^2\beta & \alpha\beta & \beta & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \alpha^{(n-1)}\beta & \alpha^{(n-2)}\beta & \alpha^{(n-3)}\beta & \dots & \beta \end{bmatrix}}_{G_u} \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \Delta u(k+2) \\ \vdots \\ \Delta u(k+N_u) \end{bmatrix} + \\
 &\underbrace{\begin{bmatrix} \gamma & 0 & 0 & \dots & 0 \\ \alpha\gamma & \gamma & 0 & \dots & 0 \\ \alpha^2\gamma & \alpha\gamma & \gamma & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \alpha^{(n-1)}\gamma & \alpha^{(n-2)}\gamma & \alpha^{(n-3)}\gamma & \dots & \gamma \end{bmatrix}}_{G_q} \begin{bmatrix} \Delta q_d(k) \\ \Delta q_d(k+1) \\ \Delta q_d(k+2) \\ \vdots \\ \Delta q_d(k+N-1) \end{bmatrix} + \\
 &\underbrace{\begin{bmatrix} \gamma & 0 & 0 & \dots & 0 \\ \alpha\gamma & \gamma & 0 & \dots & 0 \\ \alpha^2\gamma & \alpha\gamma & \gamma & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \alpha^{(n-1)}\gamma & \alpha^{(n-2)}\gamma & \alpha^{(n-3)}\gamma & \dots & \gamma \end{bmatrix}}_{G_q} \begin{bmatrix} \Delta q_e(k) \\ \Delta q_e(k+1) \\ \Delta q_e(k+2) \\ \vdots \\ \Delta q_e(k+N-1) \end{bmatrix} + \underbrace{\begin{bmatrix} \alpha \\ \alpha^2 \\ \alpha^3 \\ \vdots \\ \alpha^N \end{bmatrix}}_f y(k)
 \end{aligned} \tag{27}$$

que equivale a

$$\hat{Y} = G_U \Delta u + G_q \Delta q_d + G_q \Delta q_e + f \tag{28}$$

onde  $\hat{Y}$  é o vetor das predições da variável controlada,  $\Delta u$  é o vetor de incrementos de controle futuro,  $\Delta q_d$  é o vetor de incrementos da irradiação futura conhecida (estimada),  $\Delta q_e$  é o vetor de incrementos da incerteza futura,  $f$  representa a resposta livre do sistema e  $G_U$  e  $G_q$  são matrizes que relacionam, de forma linear, os controles e as perturbações futuras com as saídas previstas, respectivamente.

Considerando a substituição da componente estocástica  $q_e$  da perturbação  $q$  por uma variável aleatória gaussiana com média  $\mu$  e variância  $\sigma^2$ , ou seja,  $q_e \sim \mathcal{N}(\mu, \sigma^2)$ , a perturbação pode ser representada, na forma padronizada, por

$$z = \frac{q_e - \mu}{\sqrt{\sigma^2}} \tag{29}$$

sendo que  $z$  também é uma variável aleatória gaussiana, com média  $\mu_{q_e} = 0$  e variância  $\sigma_{q_e}^2 = 1$ , ou seja,  $z \sim \mathcal{N}(0, 1)$ . Desta forma, podemos reescrever a variável  $q_e$  como

$$q_e = z\sigma + \mu. \quad (30)$$

sendo  $\sigma$  o desvio padrão. A mesma análise pode ser feita para  $\Delta q_e$ .

Considerando que a variável estocástica tenha *desvio padrão constante* para todo o horizonte de predição é possível substituir (23) e (30) em (24), (25) e (26) obtendo-se

$$\hat{y}(k+1|k) = \alpha y(k) + \beta \Delta u(k) + \gamma(\Delta z(k)\sigma + \mu) + \Delta q_d(k) \quad (31)$$

$$\begin{aligned} \hat{y}(k+2|k) = & \alpha^2 y(k) + \alpha\beta \Delta u(k) + \beta \Delta u(k+1) + \alpha\gamma(\Delta z(k)\sigma + \mu) \\ & + \alpha\gamma \Delta q_d(k) + \gamma(\Delta z(k+1)\sigma + \mu) + \gamma \Delta q_d(k+1) \end{aligned} \quad (32)$$

$$\begin{aligned} \hat{y}(k+3|k) = & \alpha^3 y(k) + \alpha^2 \beta \Delta u(k) + \alpha\beta \Delta u(k+1) + \beta \Delta u(k+2) \\ & + \alpha^2 \gamma(\Delta z(k)\sigma + \mu) + \alpha^2 \gamma \Delta q_d(k) + \alpha\gamma(\Delta z(k+1)\sigma + \mu) \\ & + \alpha\gamma \Delta q_d(k+1) + \gamma(\Delta z(k+2)\sigma + \mu) + \gamma \Delta q_d(k+2). \end{aligned} \quad (33)$$

e, portanto, para o caso da variável aleatória ser modelada como uma variável gaussiana com desvio padrão constante ao longo do horizonte de predição, a equação (28) pode ser reescrita como

$$\hat{Y} = G_u \Delta u + G_q \Delta q_d + G_q l \sigma \Delta z + G_q \mu + f \quad (34)$$

sendo  $l$  uma matriz identidade de ordem  $N$  e  $\mu = 1\mu$ , com  $1$  sendo um vetor unitário de ordem  $N$ .

A equação (34) representa o modelo do sistema considerando o comportamento incerto das perturbações. Como foi dito anteriormente, caso o sistema tenha restrições a serem atendidas por um eventual controlador, faz-se necessário modelar também as restrições de forma probabilística, tema que é abordado a seguir.

### 4.2.3 Restrições Probabilísticas

Como foi explicado no capítulo 2, o Controle Preditivo Baseado em Modelo faz uso de um modelo para prever o comportamento futuro do processo e, com base nessas predições, minimizar uma função de custo ( $J$ ) sujeita a restrições nas variáveis envolvidas. Para isso, requer-se o cálculo das saídas previstas do sistema que podem ser obtidas através de (28). Porém, como na prática não se tem conhecimento dos valores futuros da parte estocástica da perturbação, não é possível calcular precisamente o valor das predições  $\hat{Y}$ . Porém, dentro do contexto probabilístico, é possível calcular a esperança matemática<sup>4</sup> das predições, como

$$\mathbb{E}\hat{Y} = \mathbb{E}[G_u \Delta u + G_q \Delta q_d + G_q \Delta q_e + f]. \quad (35)$$

<sup>4</sup> Esperança matemática (ou valor esperado) de uma variável aleatória é a soma do produto de cada probabilidade de saída da experiência pelo seu respectivo valor (PINHEIRO *et al.*, 2012).

Como a esperança de uma variável determinística é a própria variável, (35) pode ser reescrita como

$$\mathbb{E}[\hat{Y}] = G_u \Delta u + G_q \Delta q_d + f + \mathbb{E}[G_q \Delta q_e]. \quad (36)$$

Desta forma, o problema de otimização dispõe não mais das predições  $\hat{Y}$ , mas sim da  $\mathbb{E}[\hat{Y}]$ , que equivale ao valor da predição completa dada por (28) substituindo a parte estocástica da perturbação pelo seu valor esperado.

Portanto, o problema de otimização que originalmente poderia ter sido escrito como

$$\begin{aligned} \min_x \quad & J(x) \\ \text{s.a} \quad & y_{min} \leq \hat{y}(k+n|k) \leq y_{max} \end{aligned} \quad (37)$$

será reescrito como

$$\begin{aligned} \min_x \quad & \mathbb{E}[J(x)] \\ \text{s.a} \quad & \Pr \{y_{min} \leq \hat{y}(k+n|k) \leq y_{max}\} \geq (1-\delta) \end{aligned} \quad (38)$$

ambos com  $n = 1 \dots N$ .

Uma vez modelados tanto o processo quanto as restrições de forma a incluir a incerteza no modelo, faz-se necessário agregar a informação da Função Distribuição de Probabilidade da incerteza à modelagem, assunto abordado na seguinte seção.

#### 4.2.4 Restrições probabilísticas e suas determinísticas equivalentes - Incerteza como variável gaussiana

Seja uma restrição na variável de saída do tipo

$$y_{min} \leq \hat{y}(k+n|k) \leq y_{max} \quad ; \quad n = 1 \dots N. \quad (39)$$

que, na forma probabilística, resulta em

$$\Pr \{y_{min} \leq \hat{y}(k+n|k) \leq y_{max}\} \geq (1-\delta) \quad ; \quad n = 1 \dots N. \quad (40)$$

com  $\delta$  sendo o risco aceitável para a violação da restrição.

Para o primeiro instante do horizonte de predição e considerando apenas a restrição de valor máximo, obtém-se

$$\Pr \{\hat{y}(k+1|k) \leq y_{max}\} \geq (1-\delta). \quad (41)$$

Substituindo (31) em (41), obtém-se

$$\Pr \{\alpha y(k) + \beta \Delta u(k) + \gamma \Delta q_d(k) + \gamma (\Delta z(k) \sigma + \mu) \leq y_{max}\} \geq (1-\delta) \quad (42)$$

de forma que, separando a parte estocástica à esquerda e a parte determinística à direita, obtém-se

$$\Pr \left\{ \underbrace{\Delta z(k)}_{\text{Parte estocástica}} \leq \underbrace{\frac{y_{max} - \alpha y(k) - \beta \Delta u(k) - \gamma \Delta q_d(k) - \gamma \mu}{\gamma \sigma}}_{\text{Parte determinística}} \right\} \geq (1-\delta) \quad (43)$$

que equivale a encontrar a função de probabilidade acumulada ( $\varphi$ ) da parcela determinística, resultando em

$$\begin{aligned} \varphi \left\{ \frac{y_{max} - \alpha y(k) - \beta \Delta u(k) - \gamma \Delta q_d(k) - \gamma \mu}{\gamma \sigma} \right\} &\geq (1 - \delta) \\ \frac{y_{max} - \alpha y(k) - \beta \Delta u(k) - \gamma \Delta q_d(k) - \gamma \mu}{\gamma \sigma} &\leq \varphi^{-1}(1 - \delta) \\ y_{max} - \alpha y(k) - \beta \Delta u(k) - \gamma \Delta q_d(k) - \gamma \mu &\leq \varphi^{-1}(1 - \delta) \gamma \sigma \\ \underbrace{\alpha y(k) + \beta \Delta u(k) + \gamma \Delta q_d(k)}_{\mathbb{E}[\hat{y}(k+1|k)]} &\leq y_{max} - \gamma \mu - \varphi^{-1}(1 - \delta) \gamma \sigma \end{aligned} \quad (44)$$

sendo  $\mathbb{E}[\hat{y}(k+1|k)]$  a esperança matemática da previsão da saída do modelo (24) para o instante  $(k+1)$  calculado no instante  $k$ . Da mesma forma, para a restrição de valor mínimo, tem-se

$$\mathbb{E}[\hat{y}(k+1|k)] \geq y_{min} - \gamma \mu + \varphi^{-1}(1 - \delta) \gamma \sigma. \quad (45)$$

As equações (44) e (45) representam as restrições determinísticas equivalentes à restrição original (40) para o primeiro instante de previsão.

Generalizando o procedimento recursivo adotado, as restrições determinísticas equivalentes podem ser obtidas diretamente da formulação matricial da equação (28). Desta forma, é possível escrever a variável aleatória na forma multivariada como  $\mathbf{q}_e \sim \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , sendo  $\boldsymbol{\mu}$  o vetor contendo as médias e  $\boldsymbol{\Sigma}$  a matriz de covariância, ambas ao longo do horizonte de previsão, sendo que na matriz de covariância encontram-se as variâncias da variável aleatória na diagonal principal e nas demais posições as covariâncias entre as variáveis dentro do horizonte de previsão  $N$ , sendo  $\sigma_j$  o desvio padrão de cada variável gaussiana e  $\rho_{ij} \in [-1, 1]$  os coeficientes de correlação entre as variáveis  $i$  e  $j$ .

$$\boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_N \end{bmatrix} \quad (46)$$

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & \sigma_1 \sigma_2 \rho_{12} & \dots & \sigma_1 \sigma_N \rho_{1N} \\ \sigma_1 \sigma_2 \rho_{12} & \sigma_2^2 & \dots & \sigma_2 \sigma_N \rho_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_1 \sigma_N \rho_{1N} & \sigma_2 \sigma_N \rho_{2N} & \dots & \sigma_N^2 \end{bmatrix} \quad (47)$$

Entretanto, por estar tratando com uma parcela desconhecida ( $\Delta \mathbf{q}_e$ ) que tenta capturar através da sua distribuição de probabilidade alguma informação do fenômeno físico relacionado, possivelmente não se tenha disponível a informação dos coeficientes de correlação da matriz de covariância. Neste caso, é perfeitamente possível modelar a variável  $\Delta \mathbf{q}_e$  como uma variável aleatória independente, ou seja, com coeficientes de correlação iguais a zero.

Seguindo no sentido de representar as restrições determinísticas equivalentes diretamente da formulação matricial, deve-se fazer a seguinte consideração: a parcela  $G_q \Delta q_e$  de (28) nada mais é do que uma transformação linear<sup>5</sup> da variável aleatória  $\Delta q_e$ , resultando em uma nova variável aleatória n-variada  $\Delta \xi = G_q \Delta q_e$ , sendo que esta nova variável aleatória é dada por  $\Delta \xi \sim \mathcal{N}(\mu_\xi, \Sigma_\xi)$ , com  $\mu_\xi = G_q \mu$  e  $\Sigma_\xi = G_q \Sigma G_q'$ .

As restrições determinísticas equivalentes na forma matricial serão

$$\mathbb{E}[\hat{Y}] \geq y_{min} - \mu_\xi + \Sigma_\xi^{1/2} \varphi^{-1}(1 - \delta) \quad (48)$$

e

$$\mathbb{E}[\hat{Y}] \leq y_{max} - \mu_\xi - \Sigma_\xi^{1/2} \varphi^{-1}(1 - \delta) \quad (49)$$

sendo  $\mathbb{E}[\hat{Y}]$  a esperança matemática do vetor de predições  $\hat{Y}$ ,  $y_{min}$  o vetor de valores mínimos para o horizonte de predição  $N$ ,  $\mu_\xi$  o vetor com as médias resultantes de  $G_q \mu$  para o horizonte de predição  $N$ ,  $\Sigma_\xi$  a matriz de covariância ( $G_q \Sigma G_q'$ ) e  $\varphi^{-1}(1 - \delta)$  o valor da  $CDF^{-1}$  de  $(1 - \delta)$ .

A seguir, será apresentado um estudo de caso da aplicação de restrições probabilísticas em um campo solar de grande porte.

### 4.3 ESTUDO DE CASO

Neste capítulo, utiliza-se o modelo dos 4 campos conectados em *paralelo*, modelados no capítulo 3 (Eq (9) e Figura 6).

#### 4.3.1 Controle Preditivo PNMPC com uso de Predições das Perturbações

Neste capítulo será utilizado o controlador *Practical Non-Linear Model Predictive Control* (PNMPC)(PLUCÊNIO, 2010), apresentado no capítulo 3. Para o problema dos campos solares proposto neste trabalho a função custo é dada por

$$J = [\hat{Y} - W]' Q [\hat{Y} - W] + \Delta u' R \Delta u + u' M u \quad (50)$$

sendo que  $Q$ ,  $R$  e  $M$  são as ponderações das parcelas de  $J$  para seguimento de referência da temperatura do arranjo, penalização da variação do controle e minimização da vazão do sistema, respectivamente.  $\hat{Y}$  é o vetor com as temperaturas de saída do arranjo preditas,  $W$  é o vetor com as referências das temperaturas de saída do arranjo do sistema,  $\Delta u$  são os incrementos futuros de vazão em cada campo (variáveis manipuladas) e  $u$  é a vazão total do arranjo.

A função custo (50) requer o cálculo das saídas preditas do sistema que podem ser calculadas como função das variáveis de decisão  $\Delta u$  conhecendo o modelo do processo e das perturbações futuras

$$\hat{Y} = G_u \Delta u + G_i \Delta i + f \quad (51)$$

<sup>5</sup> A demonstração da transformação linear encontra-se no Anexo A.

sendo  $\Delta i$  o vetor de incrementos da irradiação futura<sup>6</sup>,  $f$  representa a resposta livre do sistema e  $G_U$  e  $G_j$  são as matrizes que relacionam, de forma linear, os controles futuros e a irradiação futura com as saídas previstas. É importante salientar que, diferentemente do controlador utilizado no capítulo 3 que usava para a ação *feedforward* valores futuros constantes e iguais ao valor atual da perturbação (instante  $k$ ), aqui utilizam-se valores futuros da irradiação dados por um estimador, estratégia que será detalhada na seção 4.3.2.

Desta forma, o problema de otimização restrito pode ser escrito como

$$\min_{\Delta u} J \quad (52)$$

s.a.

$$\hat{Y} = G_U \Delta u + G_j \Delta i + f \quad (53)$$

$$\underline{\Delta u} \leq \Delta u \leq \overline{\Delta u} \quad (54)$$

$$\hat{Y} \leq \overline{Y} \quad (55)$$

ao longo do horizonte de predição  $N$ , com  $\underline{\Delta u}$  e  $\overline{\Delta u}$  vetores contendo os mínimos e máximos incrementos de controle futuro, respectivamente;  $\overline{Y}$  o vetor contendo os limites máximos para a temperatura de saída dos campos ao longo do horizonte de predição. Para este trabalho foi definido que a restrição de limites mínimos para a temperatura de saída dos campos será tratada fora do contexto probabilístico, sendo que cada campo será desativado (vazão = zero) quando sua temperatura na saída cair abaixo da temperatura mínima  $\underline{Y}$ .

### 4.3.2 Modelagem Probabilística

A fim de incluir a incerteza das predições da irradiação futura ao modelo, os incrementos da irradiação futura  $\Delta i$  podem ser separados em

$$\Delta i = \underbrace{\Delta i_d}_{\text{determinístico}} + \underbrace{\Delta i_e}_{\text{estocástico}} \quad (56)$$

sendo  $\Delta i_d$  a parte conhecida (estimada ou histórica) e  $\Delta i_e$  a parte da incerteza que pode ser aproximada por uma Função Densidade de Probabilidade com parâmetros conhecidos, comumente através de uma variável aleatória gaussiana.

Particularmente, a irradiação solar é um fenômeno que apresenta correlação significativa apenas com a irradiação imediatamente anterior (AGUIAR *et al.*, 1988). Isto mostra a dificuldade na predição dos valores de irradiação solar e justifica a utilização da abordagem probabilística.

Dessa forma, o modelo (51) pode ser reescrito como

$$\hat{Y} = G_U \Delta u + G_j \Delta i_d + G_j \Delta i_e + f. \quad (57)$$

<sup>6</sup> Ação *feedforward*.

Considerando a parte da incerteza dos incrementos da irradiação futura como sendo uma variável gaussiana com média  $\mu = 0$  e variância  $\sigma^2$ ,  $\Delta i_e \sim \mathcal{N}(0, \sigma^2)$ , é possível obter a transformação da variável aleatória para a forma padronizada através da relação  $\Delta z(k) = (\Delta i_e(k) - \mu)/\sigma$ , obtendo

$$G_i \Delta i_e = P \Delta z \quad (58)$$

sendo  $P$  uma matriz diagonal contendo os desvios padrões <sup>7</sup> da nova variável  $\Delta z$  ao longo do horizonte de predição  $N$ .

Incorporando as incertezas da irradiação ao modelo de forma probabilística, a equação (57) pode ser reescrita como

$$\hat{Y} = G_u \Delta u + G_i \Delta i_d + P \Delta z + f. \quad (59)$$

### 4.3.3 Restrições Probabilísticas

Aplicando os conceitos da seção 4.2.3 ao caso dos campos solares, tem-se que as predições do modelo são dadas por

$$\mathbb{E}[\hat{Y}] = \mathbb{E}[G_u \Delta u + G_i \Delta i_d + P \Delta z + f]. \quad (60)$$

Como a esperança de uma variável determinística é a própria variável, a equação (60) pode ser reescrita como

$$\mathbb{E}[\hat{Y}] = G_u \Delta u + G_i \Delta i_d + f + \mathbb{E}[P \Delta z] \quad (61)$$

com  $\mathbb{E}[P \Delta z] = 0$ , pois a esperança da variável aleatória gaussiana padronizada é nula.

Desta forma, o problema de otimização dispõe não mais das predições  $\hat{Y}$ , mas sim da  $\mathbb{E}[\hat{Y}]$ , que equivale ao valor da predição completa dada por (57) substituindo a parte estocástica da perturbação pelo seu valor esperado.

Portanto, o problema de otimização (55) pode ser reescrito como

$$\min_{\Delta u} \mathbb{E}[J] \quad (62)$$

s.a.

$$\mathbb{E}[\hat{Y}] = G_u \Delta u + G_i \Delta i_d + f \quad (63)$$

$$\Delta u \leq \Delta u \leq \overline{\Delta u} \quad (64)$$

$$\mathbb{P} \left\{ \hat{Y} \leq \overline{Y} \right\} \geq p \quad (65)$$

com  $p$  sendo um vetor dos valores  $(1 - \delta)$  ao longo do horizonte de predição  $N$  e  $\delta$  o risco aceitável para a violação da restrição probabilística, configurando um problema MPC com características estocásticas.

<sup>7</sup> Os desvios padrão de uma transformação linear  $G \Delta i_e$  são a raiz quadrada dos elementos da diagonal principal da matriz de covariância  $\Sigma = (G_i \sigma G_i^T)$ .

Uma forma de utilizar a restrição probabilística (65) no problema de otimização quadrática é obtendo a sua equivalente determinística, como detalhado na seção 4.2.4. Substituindo (59) na restrição (65) obtém-se

$$\mathbb{P} \{ G_U \Delta u + G_i \Delta i_d + P \Delta z + f \leq \bar{Y} \} \geq p. \quad (66)$$

Separando a parte estocástica à esquerda e a determinística à direita, tem-se

$$\mathbb{P} \left\{ \underbrace{\Delta z}_{\text{Estocástica}} \leq \underbrace{P^{-1}(\bar{Y} - G_U \Delta u - G_i \Delta i_d - f)}_{\text{Determinística}} \right\} \geq p \quad (67)$$

que equivale à Função Densidade Acumulada (CDF) da parte determinística, resultando em

$$\varphi \left\{ P^{-1}(\bar{Y} - G_U \Delta u - G_i \Delta i_d - f) \right\} \geq p. \quad (68)$$

Substituindo (63) em (68), obtém-se a restrição determinística equivalente para a restrição probabilística (65) como

$$\hat{Y} \leq \bar{Y} - P \varphi^{-1}(\delta) \quad (69)$$

sendo  $\varphi^{-1}(\delta)$  o vetor de valores da CDF para o risco de violação da restrição  $\delta$  ao longo do horizonte de predição  $N$ . Portanto, é possível substituir a restrição probabilística (65) pela restrição determinística equivalente (69), que nada mais é do que a restrição original (55) *enrijecida*, de forma que a violação da restrição determinística resultará na violação da restrição original em  $\delta \times 100\%$  das vezes.

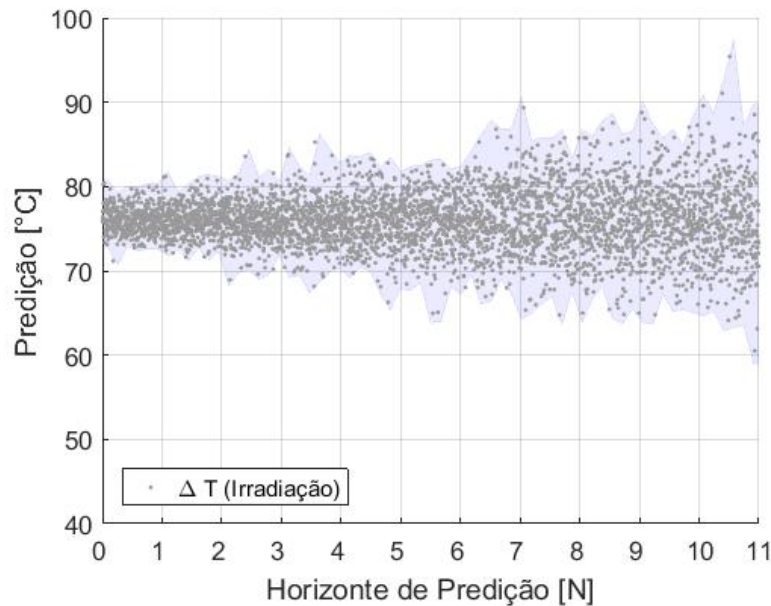


Figura 17 – Variância da variável aleatória aumentando ao longo do horizonte de predição  $N$ .

Entretanto, como é de se esperar, a variância da variável aleatória aumenta ao longo do horizonte de predição, formando uma espécie de cone, como o visto na Figura 17, podendo



causar a infactibilidade do problema de otimização. A Figura 18 mostra as restrições probabilísticas implementadas através das suas determinísticas equivalentes de forma que obtém-se uma espécie de *alinhamento* da parte superior do cone (resultante do aumento da variância da variável aleatória) com a restrição original. Ou seja, apesar do aumento da variância da variável aleatória, pelo fato de implementarem-se as restrições determinísticas equivalentes que enrijem-se com o horizonte de predição  $N$ , o resultado obtido é o atendimento (probabilístico) da restrição original.

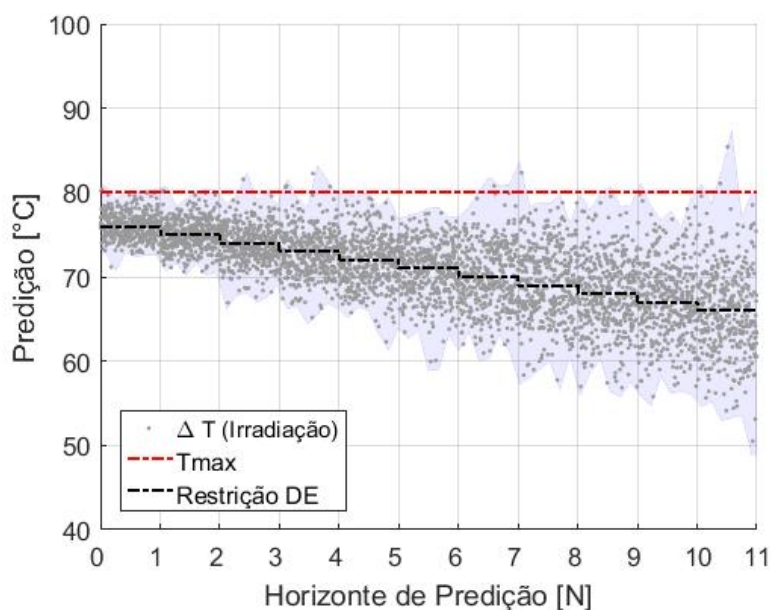


Figura 18 – Efeito da restrição probabilística que se enrijece (fica mais restritiva) ao longo do horizonte de predição  $N$ .

Contudo, o enrijecimento das restrições ao longo do horizonte de predição aliado à utilização de horizontes de predição maiores<sup>8</sup> pode resultar em conflitos com outras restrições do problema de otimização, como por exemplo, na situação em que a restrição probabilística se encontre com uma eventual restrição de mínimo, fazendo com que não haja solução do problema de otimização.

Yan e Robert R. Bitmead (2005) propõem o conceito de *covariância de malha fechada* que é a covariância do primeiro instante de predição sendo utilizada como valor constante para todo o horizonte  $N$ , como visto na Figura 19. Esta abordagem permite evitar, além dos problemas de infactibilidade, que as predições sejam demasiadamente conservadoras, o que poderia tornar impraticável a implementação das restrições probabilísticas. Neste trabalho é utilizada a covariância de malha fechada para o cálculo da restrição (69), resultando na restrição determinística

$$\hat{Y} \leq \bar{Y} - P' \varphi^{-1}(\delta) \quad (70)$$

<sup>8</sup> A escolha de horizontes de predição maiores é normalmente associada ao desejado aumento da robustez do problema em malha fechada (PARISINI; ZOPPOLI, 1995; JADBABAIE *et al.*, 2001; LIMON, Daniel, 2002)

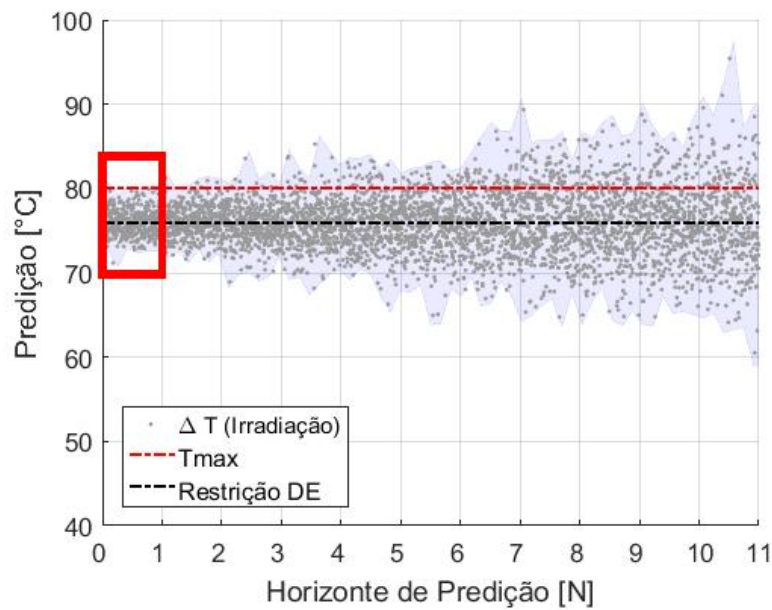


Figura 19 – Covariância de malha fechada: covariância do primeiro instante de predição sendo utilizada como valor constante para todo o horizonte  $N$ .

sendo a matriz  $P' = I_N \sigma_{(k+1)}$ , com  $I_N$  uma matriz identidade de ordem  $N$  e  $\sigma_{(k+1)}$  a raiz quadrada do primeiro elemento da diagonal principal da matriz de covariância  $\Sigma = (G_i \sigma G_i')$ .

#### 4.3.4 Resultados

Para verificar o desempenho do sistema original (apresentado no capítulo 3) em comparação com o sistema sujeito às restrições probabilísticas, ambos os casos foram submetidos à mesma irradiação solar, temperatura ambiente e temperatura da água de entrada. Para facilitar o acompanhamento do capítulo, repetem-se as figuras dos perfis de irradiação (Figura 20) e das temperaturas de entrada e ambiente (Figura 21), já apresentados no capítulo 3. Para este estudo foi definida a temperatura desejada na saída do arranjo como sendo  $70\text{ }^\circ\text{C}$ . As Figuras 22 e 23 mostram a evolução das temperaturas e das vazões dos quatro campos com o processo operando com MPC1 (determinístico) e MPC2 (estocástico) utilizando a restrição probabilística aplicada ao limite máximo de temperatura  $\bar{Y}$ . Convém destacar, e é possível perceber, que as oscilações apresentadas pelo campo 3 após 3,5 horas de simulação são resultantes da oscilação da irradiação incidente nesse mesmo instante no próprio campo e não por eventual oscilação oriunda da dinâmica do controle em malha fechada.

Na Figura 22 apresenta-se a resposta do controlador sem o uso das restrições probabilísticas (MPC1) para demonstrar que, sem elas, o sistema alcançaria temperaturas além dos limites permitidos. Obviamente que, se fossem utilizadas restrições “hard” na saída não haveria a violação nessa magnitude, mas enfrentaria-se o problema de infactibilidade devido à impossibilidade do controlador manter a saída dentro dos limites estabelecidos, como já foi comentado na seção 4.1. Ainda na mesma figura, nota-se que a temperatura de saída dos




Figura 20 – Perfil de irradiações para os diferentes campos solares

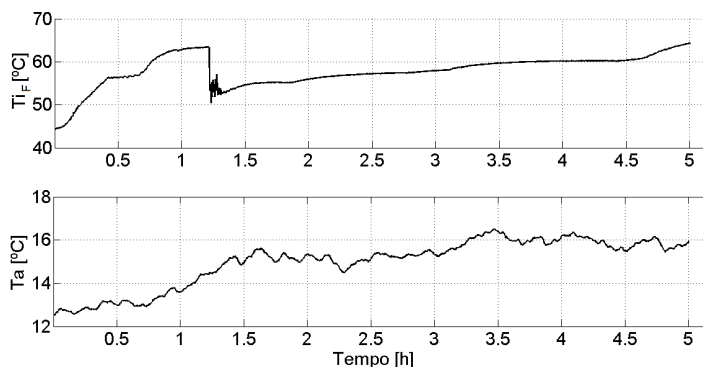


Figura 21 – Temperatura ambiente e de entrada para os quatro campos solares

campos do MPC2 (com restrições probabilísticas) é mantida aproximadamente 4°C abaixo do limite máximo estabelecido. Isto ocorre porque a restrição probabilística deixa o sistema, de certa forma, mais conservador na medida em que enrijece a restrição original por conhecer a variância do sinal da irradiação. Esta ação “protege” o sistema das eventuais variações no valor da irradiação que resultariam em violação da restrição original.

Como já foi dito, para cumprir a restrição de valor mínimo da equação (55) o sistema permite desativar o campo que estiver abaixo da temperatura aceitável<sup>9</sup> quando a sua irradiação for insuficiente para manter a temperatura da água de saída do campo dentro dos limites de operação, desde que seja atendida a restrição de vazão do arranjo. Na Figura 23 é possível verificar os momentos em que os campos são desativados (cortados), ou seja, que a vazão é

<sup>9</sup> Neste capítulo, o campo é desativado quando a temperatura de saída permanecer menor ou igual à de entrada por um período maior do que um minuto.




Figura 22 – Temperatura de saída dos campos para o MPC1 e MPC2

Tabela 4 – Integral do erro quadrático da temperatura de saída do arranjo

	MPC	ISE
MPC1 (determinístico)		1848.8
MPC2 (estocástico)		1784.0

$$ISE = \sum [w(k) - y(k)]^2.$$

igual a zero.

A Figura 24 mostra a temperatura e a vazão final do arranjo do sistema operando com os dois algoritmos MPC. Percebe-se que ambos os casos mantêm o valor da temperatura de saída do arranjo aceitavelmente em torno do valor desejado de 70°C.

O desempenho do sistema para ambos os algoritmos MPC, determinístico (MPC1) e estocástico (MPC2), pode ser comparado através da Integral do Erro Quadrático (ISE) para seguimento de referência (Tabela 4) e da Variação Total para o sinal de controle (Tabela 5).

Nota-se que a abordagem probabilística apresenta menor erro quadrático mostrando mais facilidade para o seguimento de referência. Por outro lado, as vazões dos campos apresentam maior variação total indicando que os atuadores são mais demandados para manter as temperaturas de saída dos campos dentro dos limites estipulados pelas restrições probabilísticas.




Figura 23 – Vazão dos campos para o *MPC1* e *MPC2*

Tabela 5 – Variação total do sinal de controle (vazão) dos campos TV

MPC	Campo 1	Campo 2	Campo 3	Campo 4
MPC1	85.1	81.8	51.1	56.7
MPC2	81.3	93.8	87.0	64.6

$$TV = \sum |\Delta \dot{m}(k)|$$

#### 4.3.5 Comentários Finais do Capítulo

Em sistemas de controle MPC, que utilizam a solução de problemas de otimização na sua formulação, é comum que as incertezas presentes no modelo ocasionem previsões também incertas, podendo resultar em violação indesejada das restrições do sistema em malha fechada. Para minimizar esse problema, neste capítulo incorporaram-se as incertezas ao modelo através de restrições probabilísticas de forma a minimizar o comportamento indesejado na violação das restrições e melhorar a robustez do MPC. Este capítulo apresentou os resultados e características da utilização das restrições probabilísticas aplicadas ao problema de campos solares de grande porte.

Os resultados obtidos mostram que o MPC com restrições probabilísticas permite estabelecer restrições nas variáveis de saída (ou estados) mantendo-as dentro do limite aceitável, minimizando o risco de violação das restrições.

Notou-se que o controlador atua de forma mais conservadora na medida em que enrijece

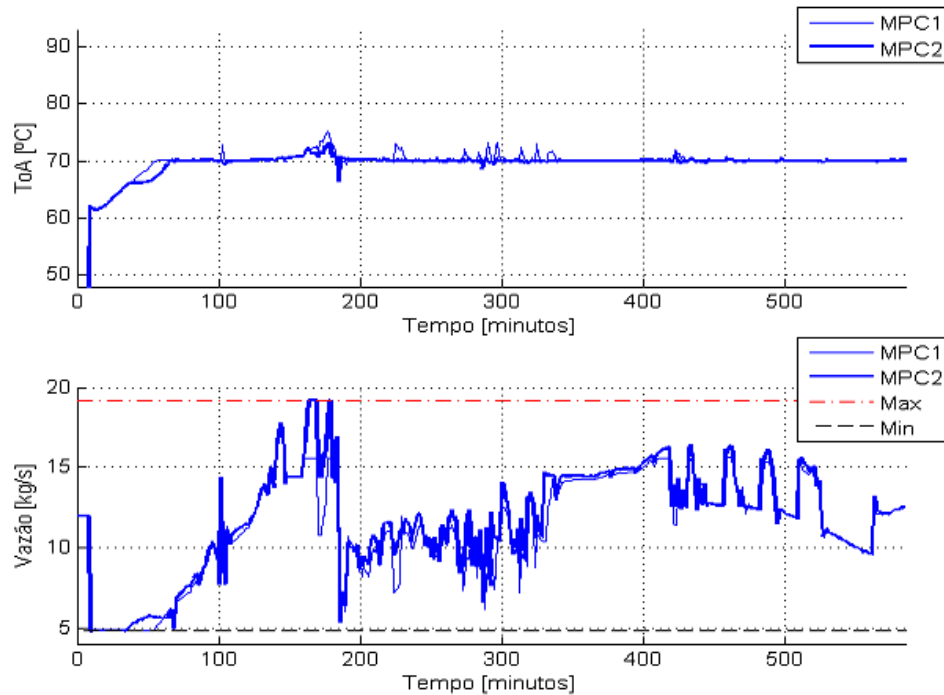


Figura 24 – Temperatura e vazão do arranjo para o *MPC1* e *MPC2*

a restrição original por conhecer a variância do sinal da irradiação, de certa forma protegendo o sistema de eventuais variações na saída causadas por fenômenos não modelados.

A principal contribuição deste capítulo é detalhar como se podem utilizar as restrições probabilísticas no contexto do MPC para sistemas sujeitos a perturbações estocásticas.

Por outro lado, a utilização da abordagem probabilística para problemas com incertezas de grande variância, como é o caso da irradiação solar, pode tornar as restrições ao longo do horizonte de predição tão conservadoras que inviabilizariam a sua utilização. Uma forma de contornar esse problema é utilizando a variância de malha fechada, conceito introduzido por Yan e Bitmead (2005). O uso das restrições probabilísticas permitem que o sistema tenha mais facilidade de permanecer na temperatura de referência, ao passo que demanda mais ação dos atuadores.

## 5 CONTROLE PREDITIVO COM RESTRIÇÕES PROBABILÍSTICAS PARA O GERENCIAMENTO EFICIENTE DE ENERGIA EM SISTEMAS DE GERAÇÃO RENOVÁVEL

### 5.1 INTRODUÇÃO

O uso de fontes renováveis para geração de energia é, sem dúvida, um tema relevante, principalmente por promover o chamado desenvolvimento ecológico sustentável. É patente que os paradigmas que envolvem a geração de energia estão mudando rápida e profundamente: as reservas naturais acessíveis de combustíveis fósseis estão diminuindo e, ao mesmo tempo, a demanda por energia cresce em todo o planeta, colocando o uso de energias renováveis em destaque.

Embora sejam diversas as vantagens do uso das energias renováveis, é importante observar que o comportamento intermitente e a sua forte dependência das condições climáticas locais tornam a utilização de tais fontes de energia um tema desafiador no que diz respeito à qualidade de energia, à segurança do sistema e à gestão da rede.

Nesse contexto, a integração de fontes renováveis a sistemas de geração de energia já existentes (não renováveis) pode ser uma alternativa para atender à demanda de energia e diminuir as emissões de gases de efeito estufa juntamente com os demais impactos ambientais decorrentes. Entretanto, um dos desafios é integrar tais fontes de energia sem degradar a eficiência do sistema mantendo a disponibilidade de fornecimento contínuo, ou seja, mantendo a despachabilidade de energia. Neste capítulo apresenta-se uma forma de integração de fontes renováveis através do conceito de microrrede<sup>1</sup> no ambiente de uma usina de cana-de-açúcar. Apresenta-se um sistema de geração de energia híbrida com o uso de algumas fontes renováveis, externas à usina, como painéis fotovoltaicos e turbinas eólicas integrando fontes de energia primária como biomassa, biogás, energia solar e eólica. Esta usina de energia foi utilizada como caso de estudo nos trabalhos de M. M. Morato *et al.* (2016), Marcelo M. Morato *et al.* (2017) e M. M. Morato *et al.* (2017), sendo que a usina é real e possui algumas das fontes de energia renovável instalada (a outra parte é proposta dos artigos).

É importante destacar que o controle da geração e armazenamento de energia em sistemas híbridos, incluindo fontes renováveis e não renováveis é um tema que vem sendo pesquisado, como por exemplo, nos trabalhos de Greenwell e Vahidi (2010) e Ferrari-Trecate *et al.* (2004). Alguns trabalhos utilizam especificamente a estratégia de Controle Preditivo aplicado ao gerenciamento de energia em microrredes com fontes renováveis. O trabalho apresentado por Valverde *et al.* (2012) mostra uma microrrede doméstica utilizando células de hidrogênio controlada por um MPC; F. Garcia-Torres e Bordons (2015) e Petrollese (2015) também apresentam trabalhos envolvendo MPC em microrredes na gestão de energia renováveis; Mendes *et al.* (2016) propõem uma estrutura MPC para gerenciamento de energia de microrredes

---

<sup>1</sup> Microrrede: conjunto de geradores, cargas e unidades de armazenamento que operam juntos, em modo isolado ou interconectados a uma rede principal Lasseter (2002).

experimentais acoplada a sistemas de armazenamento de hidrogênio. A estrutura baseada em MPC também tem provado ser eficiente para o gerenciamento de energia de sistemas híbridos de energia em Marcelo M. Morato *et al.* (2017); Hooshmand *et al.* (2013) apresentam um método de gerenciamento de energia com custo acessível para microrredes e, no trabalho mostrado por Báez-González *et al.* (2016), apresenta-se um MPC Econômico aplicado a uma usina de azeite de oliva.

Dada a característica intermitente das fontes renováveis, é evidente que uma eventual previsão do comportamento dessas fontes poderia melhorar a estabilidade interna do sistema, a segurança e a gestão da demanda de energia. Se um controlador soubesse toda a informação futura dessas perturbações poderia ser formulada uma compensação *feedforward* (*FF*) de modo que a saída da produção de energia estaria imune a essas variações.

Considerando ser possível a estimação das fontes renováveis, ainda que aproximada, para serem utilizadas por um eventual compensador *FF*, deve-se mencionar que a irradiação solar e a velocidade do vento apresentam comportamentos com componentes estocásticos, o que representa um desafio adicional no gerenciamento de energia baseada em energias renováveis. Nesse contexto, para o sistema híbrido de geração estudado nesta tese, a estimativa do comportamento futuro de variáveis consideradas como perturbações é um fator relevante e que modifica sensivelmente o resultado final oferecido pela estratégia de controle, como foi mostrado no capítulo 4 no caso dos campos solares. A importância da estimativa de distúrbios é amplamente discutida em Pawlowski *et al.* (2010), Pawlowski *et al.* (2011), Mohandes *et al.* (1998) e Christo *et al.* (2016), onde, usando diversas abordagens, melhora-se a performance do sistema de controle com o uso de estimadores de perturbação.

A comunidade de Controle de Sistemas tem elogiado alguns trabalhos na área de gerenciamento de energia para microrredes com distúrbios estocásticos, como pode ser visto nos trabalhos de Meibom *et al.* (2011), Yu *et al.* (2013) e Hovgaard *et al.* (2011). No entanto, deve ser mencionado que os novos trabalhos que lidam com perturbações estocásticas se inclinam para a abordagem das chamadas *Chance Constraints* (*CC*) ou Restrições Probabilísticas. As *CC* representam uma abordagem estocástica para problemas de otimização sob a presença de perturbações e provaram ter inúmeras aplicações em engenharia. A utilização de *CC* juntamente com MPC é explorado com detalhes por Farina *et al.* (2016). No trabalho de Velarde *et al.* (2017) e Yo *et al.* (2014), o MPC é usado para lidar com o comportamento estocástico de fontes renováveis. Aplicações recentes considerando o controle sob perturbações estocásticas para usinas de energia renovável também são apresentadas nas seguintes referências: Lubin *et al.* (2016), Olivares *et al.* (2015), Ran Wang *et al.* (2014) e Su *et al.* (2014).

Tendo em mente o atual contexto energético e a busca pela integração de fontes renováveis no âmbito do controle e gerenciamento de energia, apresenta-se nesta tese uma estratégia de controle avançado de três camadas, sendo as duas últimas executadas em paralelo. Essa estratégia é aplicada a uma usina de geração híbrida de energia com o objetivo de otimizar o seu desempenho atendendo aos requisitos operacionais do sistema.



O funcionamento do sistema pode ser descrito, de maneira resumida, definindo o escopo de cada uma das camadas do controlador. A camada superior de controle é composta por um sistema supervisorio que é responsável por decidir a meta mensal de produção de energia, meta esta que será repassada para a camada imediatamente inferior como referência de produção; a segunda camada é composta por um controlador preditivo com o uso de técnicas estocásticas de atendimento de restrições que visa fornecer pontos de operação estáveis para a planta que atendam às metas estabelecidas pela camada superior e respeitem as restrições do sistema; uma terceira camada que é executada paralelamente à anterior consiste em uma etapa de estimação de perturbações (irradiação solar) com horizontes de previsão de longo prazo, como mostrado por Reikard (2009), responsável por fornecer previsões de perturbações futuras em diferentes escalas de tempo para as outras duas camadas.

O objetivo dessa estrutura de controle avançado é de ser capaz de, levando em conta o efeito das previsões das perturbações das fontes renováveis, estabelecer metas atingíveis de produção de energia dadas as condições reais de operação do sistema. Portanto, apresenta-se neste capítulo: a) uma estrutura de controle para microrredes de geração de energia híbrida distribuída, com base nos trabalhos de M. M. Morato *et al.* (2016) e Marcelo M. Morato *et al.* (2017) e b) uma solução ótima para o problema de atendimento de contrato de geração de energia que acopla esquemas de controle preditivo com métodos precisos de estimativa de perturbação, como discutido por Pawlowski *et al.* (2011) e a estrutura Chance Constraints.

## 5.2 CASO DE ESTUDO - USINA DE CANA-DE-AÇÚCAR

Esta seção tem como objetivo descrever o problema geral a ser resolvido neste capítulo. Primeiramente, apresenta-se a usina de estudo de caso e, em seguida, descreve-se o contrato de energia elétrica a ser cumprido, formalizando o problema.

### 5.2.1 Descrição da Usina

Neste trabalho, considera-se o cenário energético brasileiro que tem como característica uma matriz energética bem diversificada (MINISTÉRIO DE MINAS E ENERGIA, 2015), onde as usinas de processamento de cana-de-açúcar, estudadas por González (2011), são particularmente significativas quando consideradas como microrredes de geração híbrida (MORATO, Marcelo Menezes *et al.*, 2016a) (MORATO, Marcelo Menezes *et al.*, 2017) (MORATO, Marcelo Menezes *et al.*, 2016b).

A usina aqui apresentada é uma usina de energia que foi proposta pela primeira vez em M. M. Morato *et al.* (2016) e consiste em uma usina de cana-de-açúcar real cujo objetivo é atender às demandas de processos internos (elétricos e a vapor), além de garantir o atendimento de um contrato de venda de energia para a rede externa, resultando em um contrato multi objetivo que será detalhado mais à frente.

Nesta usina de processamento de cana-de-açúcar produz-se açúcar, etanol e energia

elétrica. O sistema é composto pelos seguintes subsistemas: duas caldeiras e duas turbinas a vapor, cada um desses equipamentos com eficiências diferentes; um sistema de cogeração que produz e utiliza, de forma combinada, calor e energia elétrica, chamado de CHP; um resfriador de água; um tanque de água quente; painéis fotovoltaicos; painéis solares de aquecimento de água; uma turbina eólica; duas válvulas de redução de pressão; um trocador de calor; armazenamentos de bagaço, palhiço e biogás comprimido, além de um banco de baterias. Uma característica interessante do ponto de vista econômico e sustentável é que esta usina, além de utilizar fontes renováveis para geração de energia, propõe reciclar todos os resíduos de cana-de-açúcar para a própria geração de energia.

No que diz respeito às demandas a serem atendidas pela planta, tem-se: a demanda de energia elétrica da própria usina; demandas de vapor de média e baixa pressão, definidas pelas demandas do processo; e a demanda de água gelada do sistema de refrigeração, usada para resfriar os geradores, tanques de óleo e as unidades de fermentação. Deve-se ter em mente que, dada a característica do sistema que interliga todas as etapas de geração e produção da planta, a satisfação de cada uma das demandas deve ocorrer concomitantemente, não interessando o atendimento isolado de alguma restrição do processo.

Para melhor compreensão do problema a ser estudado e da proposta apresentada, descreve-se a seguir o funcionamento da usina com mais detalhes. A Figura 25 mostra um esboço das partes da usina, sendo que a Tabela 6 descreve cada uma das partes destacadas;  $Q_E^A$  e  $Q_E^B$  representam os fluxos de entrada de biomassa, medidos em  $(\frac{Mg}{h})$ , ou seja, tonelada por hora. O sistema funciona da seguinte forma: O bagaço e palhiço são queimados nas caldeiras para produzir vapor, que por sua vez, aciona as turbinas. Estas, por sua vez e por estarem acopladas a geradores elétricos, fornecerão energia tanto para as demandas internas da usina quanto para atender ao contrato de venda de energia para a rede externa. Adicionalmente, a planta conta com geradores eólicos e painéis fotovoltaicos que contribuem para a geração de energia elétrica. Por outro lado, a vinhaça, subproduto do etanol, é transformada em biogás que é usado como combustível para o cogrador de energia (*Combined Heat and Power - Cogeração (Combined Heat and Power) (CHP)*), que é um sistema que fornece, além de energia elétrica, calor para ser utilizado nas demandas de água quente da planta. A demanda de frio é atendida pelo *Chiller*, que é alimentado com água quente proveniente de painéis heliotérmicos e do próprio CHP.

O modelo matemático da usina foi elaborado utilizando o paradigma da modelagem em espaço de estados, sendo que cada estado do sistema representa um acumulador (armazenamento interno) e  $x_S(k)$  representa o estado em questão no instante de tempo  $k$ . Por outro lado, a usina possui unidades intermediárias de armazenamento que permitem que o sistema acumule energia (ou biomassa, que pode ser convertida em energia) quando a geração renovável é alta, utilizando esses estoques quando algum tipo de fonte de energia eventualmente não seja suficiente.

De um ponto de vista de tempo discreto, um estado  $x_S$ , no tempo de amostragem

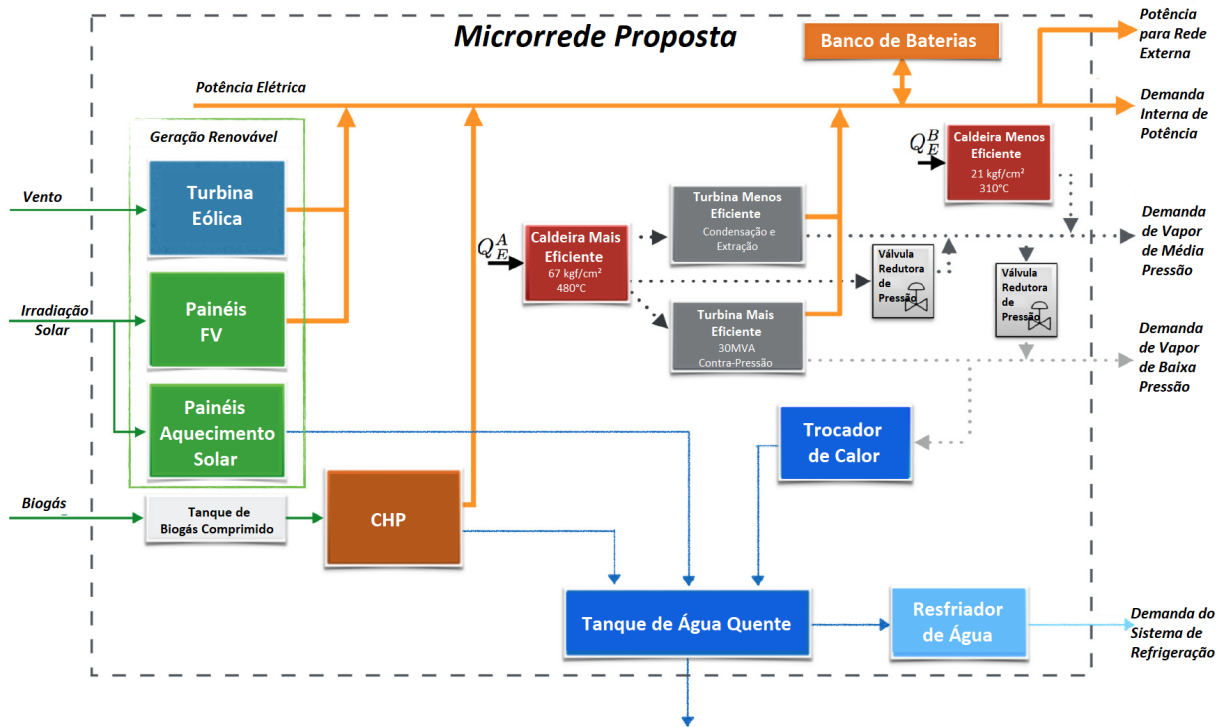


Figura 25 – Caso de estudo analisado: Planta de geração de energia híbrida

Tabela 6 – Caso de estudo: Variáveis manipuladas

Simbolo	VM	Unidade
$SP_C^B$	Setpoint da caldeira menos eficiente	$\left(\frac{Mg}{h}\right)$
$SP_{TU}^B$	Setpoint da turbina menos eficiente	(kW)
$SP_{TU}^A$	Setpoint da turbina mais eficiente	(kW)
$Pot_{Bat}$	Fluxo de energia para o banco de baterias	(kW)
$SP_{CHP}$	Setpoint do CHP	(kW)
$SP_{ch}$	Setpoint do resfriador de água	$\left(\frac{m^3}{h}\right)$
$SP_{TC}$	Setpoint do aquecedor	$\left(\frac{m^3}{h}\right)$
$Q_V^{Out}$	Setpoint da válvula de redução de pressão - Alta para Média pressão	$\left(\frac{Mg}{h}\right)$
$Q_V^{MB}$	Setpoint da válvula de redução de pressão - Média para baixa pressão	$\left(\frac{Mg}{h}\right)$
$Q_{Esc}^{Tank}$	Fluxo de água quente	$\left(\frac{m^3}{h}\right)$
$Q_{Esc}^M$	Fluxo de vapor de média pressão	$\left(\frac{Mg}{h}\right)$
$Q_{Esc}^B$	Fluxo de vapor de baixa pressão	$\left(\frac{Mg}{h}\right)$
$Pot_{Net}$	Potência elétrica disponibilizada para a rede	(kW)

$k + 1$ , depende do estado da amostra anterior  $k$  e do fluxo total trocado  $u_S^E(k)$  durante o período  $\Delta T$ , variando de  $k$  a  $k + 1$ ; Assume-se que  $u_S^E(k)$  permanece constante durante  $\Delta T$ , isto é:  $x_S(k + 1) = A_S x_S(k) + u_S^E(k) \Delta T$ .

Como descrito no trabalho de Geidl (2007), o modelo discreto no espaço de estados

da planta estudada pode ser descrito por

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) + Cq(k) \\ y(k) &= Dx(k) + Eu(k) + Fq(k) \end{aligned} \quad (71)$$

com o vetor de estado do sistema dado por

$$x(k) = \left[ X_{Bat}(k) \ X_{Bag}(k) \ X_{Str}(k) \ X_{Bg}(k) \ X_T(k) \right]^T \quad (72)$$

sendo que cada entrada representa a porcentagem normalizada dos estoques: banco de baterias, estoque de bagaço, estoque de palhiço, estoque de biogás e tanque de água quente.

O vetor de variáveis manipuladas ( $u$ ), mostradas na Tabela 6, são os *setpoints* enviados aos controladores internos de nível inferior, dado por

$$\begin{aligned} u(k) = [ & SP_{TU}^A(k) \ SP_{TU}^B(k) \ Pot_{Net}(k) \ SP_C^B(k) \ \dots \\ & Q_V^{Out}(k) \ Q_{Esc}^M(k) \ Q_{Esc}^B(k) \ SP_{CHP}(k) \ \dots \\ & SP_{Ch}(k) \ SP_{TC}(k) \ Pot_{Bat}(k) \ Q_V^{MB}(k) \ Q_{Esc}^T(k) ]^T \end{aligned} \quad (73)$$

O vetor de saída é definido como

$$y(k) = Dem(k) = \left[ P_{Dem}(k) \ Q_V^M(k) \ Q_V^L(k) \ Q_{CW}(k) \ P_{Sale}(k) \right]^T \quad (74)$$

sendo  $P_{Dem}$  a energia elétrica produzida para atender à demanda de processamento de cana-de-açúcar ( $kW$ );  $Q_V^M$  o fluxo de vapor de média pressão ( $\frac{Mg}{h}$ );  $Q_V^L$  o fluxo de vapor de baixa pressão ( $\frac{Mg}{h}$ );  $Q_{CW}$  o fluxo de água gelada requerido pelo processo da destilaria ( $\frac{Mg}{h}$ ); e  $P_{Sale}$  representa a energia elétrica disponibilizada para a rede externa ( $kW$ ) (vendida à concessionária).

As perturbações do sistema são dadas por

$$q(k) = \left[ Wnd_{in}(k) \ Irrd_{in}(k) \ Bag_{in}(k) \ Str_{in}(k) \ Bg_{in}(k) \right]^T \quad (75)$$

sendo  $Wnd_{in}$  a velocidade do vento (medida em  $\frac{km}{h}$ ) que alimenta as turbinas eólicas para geração de energia elétrica;  $Irrd_{in}$  a irradiação solar (medida em  $\frac{W}{m^2}$ ) que incide nos painéis solares da microrrede (para geração de energia elétrica e aquecimento de água);  $Bag_{in}$ ,  $Str_{in}$  e  $Bg_{in}$  representam, em  $\frac{Mg}{h}$ , a chegada de bagaço, palhiço e biogás comprimido em seus estoques, respectivamente. Cabe ressaltar que as perturbações externas futuras são estimadas para serem usadas pelo controlador, conforme detalhado na seção 5.3.1. O modelo matemático do processo foi obtido e validado através de simulação baseada em dados experimentais. Mais detalhes podem ser obtidos em (MORATO, M. M. *et al.*, 2016) e (MENDES, 2016).

### 5.2.2 O contrato de fornecimento de energia elétrica multi objetivo

A usina sucroalcooleira considerada neste capítulo deve cumprir com as demandas internas de energia elétrica decorrentes do processamento de cana-de-açúcar, que representam,

em média,  $5.76 \text{ GWh}$  ao mês. Além disso, deve atender a um contrato de venda de energia para a rede externa *Operador da Rede de Distribuição de Energia* (Distribution Network Operator) (*DNO*) constituído das seguintes condições:

- a usina deve fornecer à rede externa um mínimo de  $\chi = 11,52 \text{ GWh}$  por mês;
- se a usina fornecer apenas o valor mínimo do contrato será dispensada do pagamento de taxa de transmissão. Caso contrário, se optar por vender mais energia do que o mínimo contratado  $\chi$ , a usina deverá arcar com o custo de transmissão dessa energia extra que está sendo enviada.

Levando em conta os custos de transmissão, o fornecimento de energia superior ao mínimo contratado  $\chi$  só é conveniente (lucrativo) se a venda de energia for superior a  $2\chi$  por mês. Portanto, as metas de produção de energia devem estar dentro de uma região definida como região viável, que é ilustrada na Figura 26. É importante destacar que: a) a capacidade de geração da usina em questão é de  $2.3\chi$  ao mês; e b) o contrato admite uma tolerância de  $\psi = 15\%$  quando a produção estiver acima de  $\chi$  (isto é, nessa faixa não se cobra o custo de transmissão).




Figura 26 – Regras para atendimento do contrato de venda de energia

Portanto, o objetivo geral deste estudo de caso pode ser resumido como: projetar um controlador que, levando em conta critérios econômicos na sua formulação, encontre o melhor ponto de operação do sistema minimizando perdas, atendendo às regras contratuais e suprindo as demandas internas do processo. Evidentemente, dado o aspecto natural das fontes renováveis, tal controlador buscará utilizar ao máximo tais recursos, pois desta forma pode ser estendido o fornecimento de energia para a concessionária (em meses)<sup>2</sup>.

Uma solução possível para buscar o atendimento do contrato é a utilização do chamado controlador por faixas (o mesmo utilizado no capítulo 3, no qual utilizam-se parcelas na função objetivo do problema de otimização para minimizar a possibilidade de que uma situação indesejada ocorra. Entretanto, nesta tese utiliza-se o contexto probabilístico das chamadas restrições probabilísticas que oferecem, em algum grau, garantias de que a ocorrência da situação indesejada possa ser parametrizada no problema de otimização.

<sup>2</sup> Geralmente, o bagaço disponível nas usinas é suficiente para algo em torno de 10 meses de operação das unidades geradoras

### 5.3 SOLUÇÃO PROPOSTA

Esta seção apresenta a solução proposta para o problema descrito anteriormente. É importante destacar que a solução apresentada tem foco nas regras de produção de energia e no cumprimento do contrato baseando-se em uma estrutura hierárquica de controle, formalmente definida por Galus e Art (2012) e detalhada nesta seção.

A planta em questão deve produzir a quantidade de energia elétrica definida pelo contrato e, ao mesmo tempo, atender a todas as demandas do sistema: demanda interna de energia, demanda de vapor e demanda de refrigeração. O controlador deve calcular o valor das variáveis manipuladas (73) para que a produção mensal de energia corresponda aos *setpoints* impostos, mantendo tanto o vetor de variáveis manipuladas quanto o vetor de estado do sistema (72) dentro das faixas de operação admissíveis. Além disso, o vetor de saída do sistema (74) deve atender às demandas.

A estratégia de controle hierárquico proposto possui uma camada superior de supervisão e controle, com período de amostragem de 24 horas, composta por uma máquina de estados finitos (Máquina de Estados Finitos (FSM)) que calcula o objetivo da produção diária de energia, assim como a meta de produção de energia ao longo do mês, levando em conta o comportamento estocástico das fontes renováveis. Tais objetivos são repassados, como *setpoints*, para uma camada inferior da estrutura hierárquica, denominada, daqui em diante, de MPC-CC, cujo período de amostragem é de 1 hora, composta por um controlador MPC projetado com restrições do tipo probabilísticas para poder enfrentar a estocasticidade das fontes renováveis de energia. Tal camada tem como objetivo, levando em conta os *setpoints* da camada anterior, calcular qual deve ser a produção de energia a cada hora. Essas duas camadas trabalham em paralelo com uma terceira camada, responsável pelas estimativas de distúrbios futuros, que usa uma técnica baseada em redes neurais auto-regressivas não lineares. A informação de perturbação futura estimada é passada em períodos diferentes para cada uma das camadas, segundo o seus períodos de amostragem. Uma representação visual deste esquema de controle avançado pode ser visto na Figura 27, onde  $q$  representa os distúrbios e  $\hat{q}$  suas respectivas estimativas.

A seguir, cada uma das três camadas do esquema de controle proposto é detalhado.

#### 5.3.1 Estimador de Perturbações

Dado que um controlador MPC leva em conta um modelo de comportamento do sistema, a camada MPC pode considerar valores futuros das perturbações para encontrar, através da solução de um problema de otimização, os valores das variáveis manipuladas que permitam satisfazer as demandas de energia para o horizonte de predição do controlador.

Na estrutura de controle proposta para a usina de cana-de-açúcar em questão, as perturbações a serem estimadas são a velocidade do vento e a irradiação solar. As curvas estimadas baseiam-se em dados meteorológicos reais da própria usina, localizada no estado do

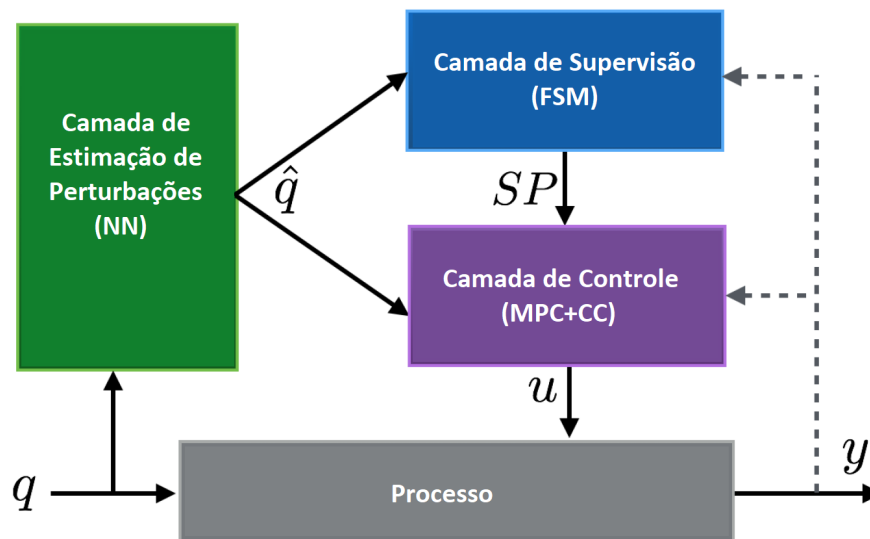


Figura 27 – Estrutura de controle hierárquico proposta

Paraná, Brasil.

O método de estimação usado é baseado em Redes Neurais Auto-Regressivas Não Lineares com atrasos temporais (Redes Neurais Auto-Regressivas Não Lineares (NN)). Em G Peter Zhang (2003) pode ser vista uma aplicação bem sucedida do uso de Redes Neurais para prever séries temporais. Uma série temporal pode ser definida como uma sequência contínua ou discreta de eventos, como estados (HAMILTON, 1994), e pode ser aplicada para identificar e analisar a natureza de diferentes fenômenos. Em Christo *et al.* (2016) NN são usadas para prever as curvas de velocidade do vento, abordagem que foi utilizada neste trabalho.

O funcionamento de uma rede neural artificial, cujo elemento básico é o neurônio artificial, pode ser descrito, resumidamente, como o resultado de conjuntos de sinapses (conexões de entrada,  $x_1 x_2 \dots x_m$ ), ponderadas por pesos individuais ( $w_{k_1} w_{k_2} \dots w_{k_m}$ ), cujo resultado é somado a um *bias* (*offset*)  $b_k$  que produz o nível de atividade  $v_k$ . Este nível de atividade é responsável pela ativação (ou não) de uma função de ativação,  $\phi(\cdot)$ , resultando no valor da saída  $y_k$ . A topologia dos neurônios de uma NN é vista na Figura 28.

Adicionalmente, uma etapa de validação de dados é utilizada para detectar eventuais inconsistências com dados perdidos e corrigí-los, de forma que as redes neurais não recebam dados corrompidos, o que poderia resultar em estimativas baseadas em dados inconsistentes.

É importante destacar que o estimador de perturbações realiza duas previsões diferentes para cada tipo de perturbação: uma com um horizonte de 24 h, utilizada nas previsões horárias e diárias e outra que estima o comportamento das perturbações no horizonte de um mês, resultado da soma dos valores horários. Esses dois preditores são detalhados a seguir.

### 5.3.1.1 Preditor de hora em hora (H-H)

A camada MPC precisa levar em conta valores futuros das perturbações para poder calcular as variáveis manipuladas que satisfaçam as restrições do problema de otimização,




Figura 28 – Rede Neural Artificial

dentre as quais estão as demandas de energia elétrica. Tais estimativas são fornecidas pelo preditor Preditor de hora em hora (H-H), atualizado essa informação a cada  $T_S = 1$  h.

O preditor de hora em hora fornece previsões de velocidade do vento e irradiação solar, sendo que há uma rede neural para cada uma dessas duas perturbações. O número de camadas e neurônios para ambas as Redes Neurais é visto na Tabela 7, sendo que para o caso da previsão da velocidade do vento foi utilizada uma rede neural com duas camadas, sendo a primeira com dois neurônios e a segunda com um.

Tabela 7 – Rede Neural utilizada para o preditor H-H

	1 h - Vel. Vento	1 h - Irr. Solar
Camadas	2	1
Neurônios	[2, 1]	1
Atraso	[48, 48]	288

O projeto e treinamento das redes neurais utilizadas neste trabalho foram desenvolvidos utilizando o software *MATLAB* (MATHWORKS, 2009) usando o algoritmo de otimização *Levenberg-Marquard* (MORÉ, 1978), que estabelece o bias e pesos para cada rede neural. O tempo de treinamento da rede foi de 60 dias, sendo um dia para validação.

Alguns resultados de estimação do preditor H-H usando a técnica NN são apresentados a seguir. As Figuras 29 e 30, respectivamente, mostram a previsão da velocidade do vento e da irradiação solar presentes na usina para um horizonte de 12 h considerando as previsões diárias (ao meio dia). Além disso, os dados meteorológicos reais são mostrados nas mesmas figuras para fins de comparação.

A Tabela 8 mostra a eficiência dos resultados de estimação apresentados através do erro relativo médio  $MRE = \left( \frac{\sum_{k=0}^{N_p} (|q_i(k) - \hat{q}_i(k)|)}{N_p} \right) / q_i(k)$  de ambas as previsões do preditor H-H.

Como pode ser visto, os preditores H-H fornecem estimativas próximas aos dados reais.






Figura 29 – Estimação da velocidade do vento com a técnica NN do preditor H-H




Figura 30 – Estimação da irradiação solar com a técnica NN do preditor H-H

Os erros de previsão serão tratados pela abordagem das restrições probabilísticas, detalhada mais adiante.

### 5.3.1.2 Preditor Diário D-D

A camada FSM, que estabelece os *setpoints* diários de produção de energia, precisa apenas da informação do efeito das perturbações totais na usina, pois a relação entre a geração

Tabela 8 – Estimação de perturbações futuras: Erro médio relativo do preditor H-H

Horizonte	Velocidade do vento	Irradiação solar
1 h	17.8 %	16.5 %

de energia pelas fontes renováveis e seu efeito a cada hora é assumido como linear, ou seja,  $E_{Ren. Sou.}^{Fim do Dia} = \lambda \sum_{k=1}^{24} q(k)$ , onde  $\lambda$  é um coeficiente proporcional e  $k$  representa o índice de tempo para cada hora do dia.

As informações fornecidas pelo preditor diário são passadas para a camada FSM, atualizadas a cada  $T_S = 24$  h.

Diferentemente do preditor H-H, o preditor D-D fornece a quantidade estimada de energia proveniente de fontes renováveis, isto é, a estimativa de produção de energia de cada fonte renovável, medida em kWh. Mais uma vez, uma rede neural é considerada para cada uma das perturbações. O número de camadas e neurônios para cada uma dessas redes pode ser visto na Tabela 9.

Tabela 9 – Rede Neural do Estimador diário D-D

	24 h - Vel. Vento	24 h - Irr. Solar
Camadas	1	1
Neurônios	3	5
Atraso	24	24

Para este caso, o mesmo algoritmo de computação e treinamento usado no preditor anterior foi aplicado. O tempo de treinamento da rede foi de 120 dias, sendo 15 dias para validação.

As Figuras 31 e 32 mostram, respectivamente, a previsão da velocidade do vento e da irradiação solar presentes na usina para um horizonte de 15 dias, considerando a quantidade de energia proveniente das fontes renováveis a cada dia. Além disso, os dados meteorológicos reais são mostrados nessas mesmas figuras, para fins de comparação. A Tabela 10 mostra o erro relativo médio do preditor diário.

Tabela 10 – Estimação de perturbações futuras: Erro médio relativo do preditor D-D

Horizonte	Vel. Vento	Irr. Solar
24 h	20.4 %	2.6 %

Assim como o preditor de hora a hora, esse preditor também possui um erro de previsão que será tratado pela abordagem das restrições probabilísticas.




Figura 31 – Estimação da velocidade do vento com a técnica NN do preditor D-D




Figura 32 – Estimação da irradiação solar com a técnica NN do preditor D-D

### 5.3.1.3 Restrições Probabilísticas (CC)

Como já analisado no capítulo 4, as perturbações estocásticas serão consideradas no contexto das restrições probabilísticas (*Chance Constraints - CC*) (JOHN R. BIRGE, 1997), (SCHWARM, Alexander T; NIKOLAOU, 1999b). O trabalho de Grosso *et al.* (2014) apresenta um controlador preditivo projetado com restrições probabilísticas para o gerenciamento de redes de água potável com bons resultados. Aplicações desta técnica ao gerenciamento de energia foram recentemente feitas por Oldewurtel *et al.* (2010).

Como foi dito na seção 4.2, em problemas de controle preditivo é possível considerar a compensação *feedforward* de perturbações futuras. Isto é, se um comportamento futuro de perturbação é completamente conhecido (hipoteticamente), uma ação *FF* adicionada ao

controlador deve tornar as saídas do sistema imunes a qualquer variação proveniente destas perturbações. No entanto, quando uma perturbação não é mensurável, para usar a compensação FF é possível utilizar uma estimativa da perturbação ( $\hat{q}$ ), embora isso ainda possa resultar em alguma variação de saída devido a partes mal estimadas de  $q$ .

Assim como no capítulo anterior, aqui se realizará a transformação de uma restrição do tipo

$$y_{min} \leq \hat{y}(k + n|k) \leq y_{max} \quad (76)$$

em uma restrição do tipo

$$\Pr\{y_{min} \leq \hat{y}(k + n|k) \leq y_{max}\} \geq (1 - \delta) \quad (77)$$

sendo o operador  $\Pr\{\cdot\}$  a probabilidade de ocorrência de uma variável,  $n$  variando de 1 até o horizonte de predição dado  $N_p$  e  $\delta$  representa o risco de violação da restrição.

No que diz respeito ao erro do estimador, tal variação é modelada pela própria Função densidade de probabilidade (PDF) do estimador, que pode ser calculada através da comparação dos dados históricos reais e suas respectivas previsões. Considerando que o objetivo é obter informações do erro de predição da energia gerada, seja pela turbina eólica ou pelos painéis solares, foi decidido encontrar as distribuições de probabilidade dos erros de ambas as perturbações juntas. A PDF empírica e a Função de Densidade Cumulativa (CDF) do erro de predição para ambos os distúrbios adicionados são mostrados na Figura 33 para o preditor de hora em hora H-H e, na Figura 34, para o preditor diário D-D.

Outro elemento que tem características estocásticas é a entrada de bagaço. A proporção de entrada de bagaço e palhiço pode ser assumida como linearmente proporcional à chegada da cana-de-açúcar<sup>3</sup>. Para cada tonelada de cana-de-açúcar processada, 250 kg de bagaço podem ser recuperados e, em média, 75 kg de palhiço. O comportamento da chegada da cana-de-açúcar na usina foi aproximado, através da análise de dados históricos, por uma distribuição gaussiana de média zero e desvio padrão 0,07. A PDF e a CDF do insumo da cana-de-açúcar e, conseqüentemente, da entrada do bagaço e do palhiço são vistos na Figura 35.

Assim como nos capítulos anteriores, cada uma das perturbações não despacháveis são modeladas como  $q = q_d + q_s$ , onde  $q_d$  (parte determinística) deriva das previsões da Rede Neural e  $q_s$  (parte estocástica) é o componente incerto dessas previsões.

Utilizando o mesmo desenvolvimento do capítulo anterior, obtém-se as restrições determinísticas equivalentes às probabilísticas

$$y_{max} - \varphi^{-1}(\delta)\gamma \geq \hat{y}[k + 1|k] \geq y_{min} + \varphi^{-1}(\delta)\gamma \quad (78)$$

que serão usadas no problema de otimização a ser resolvido pelo MPC.

<sup>3</sup> O palhiço é parte da cana-de-açúcar colhida e o bagaço é o resultado do processo de prensagem da cana-de-açúcar.




Figura 33 – PDF e CDF do erro de previsão do estimador H-H da soma das fontes não despacháveis de energia

### 5.3.2 Camada de Decisão e Supervisão

Nesta seção será descrito como a camada de supervisão do processo e de decisão foi projetada. Esta camada é composta por uma máquina de estados finitos (FSM) de três estados, correlacionados com as metas de produção de energia:  $\chi$ ,  $2\chi$  e  $2,3\chi$ . Como dito anteriormente,  $\chi$  representa a geração de energia mínima contratual de 11,52 GWh por mês. Todos os dias, a FSM decide se altera ou não o estado, modificando os *setpoints* que são passados para a camada de controle. É importante observar que essa camada de decisão atua a cada  $\Delta T = 24$  h. O período de amostragem escolhido foi estabelecido através do estudo de simulação, de forma que tal valor mostrou-se apropriado para evitar variações indesejadas dos *setpoints*, evitando oscilações nas previsões meteorológicas do MPC (camada inferior).

O objetivo da camada de decisão e supervisão é maximizar a produção de energia no final do mês ( $P_k$ ) evitando a região de penalidade  $1\chi \leq P_k < 2\chi$ . Considerando que a estrutura de supervisão sabe quanta energia já foi produzida, assim como as futuras estimativas de perturbação, é possível fazer uma estimativa de produção máxima no final do mês (ver modelo em (71)), dada por

$$\hat{P}_k = \sum_{k=hoje}^N P_{Cont}(k) + APE \quad (79)$$






Figura 34 – PDF e CDF do erro de previsão do estimador D-D da soma das fontes não despacháveis de energia

sendo  $P_{Cont}(k)$  a energia a ser produzida todos os dias, APE a energia produzida acumulada, *hoje* o dia atual e  $N$  o horizonte de previsão.

Considerando os casos de ter ou não informações sobre o erro de previsão, dois problemas de otimização (Problema de Otimização (OP)) diferentes devem ser resolvidos a cada dia ( $k$ ), sendo  $OP_{Det}$  o problema a ser resolvido em caso de previsões chamadas de determinísticas (sem informações sobre o erro de estimação) e  $OP_{Stoch}$  no caso estocástico (com a informação de erro de estimação). A ideia principal da utilização da abordagem estocástica é minimizar o risco de que a produção  $P$  resulte, ao final do mês, na região não lucrativa.



(a) PDF



(b) CDF

Figura 35 – PDF e CDF da entrada de cana-de-açúcar

$$OP_{Det} \triangleq \min_{P_{Cont}} -\hat{P}_k \quad (80a)$$

$$\begin{aligned} \text{s.t. } P_{Dem}(k+l) + P_{Cont}(k+l) &= P_{Tur A}(k+l) \\ &+ P_{Tur B}(k+l) + P_{CHP}(k+l) \\ &+ P_{Wind}(k+l) + P_{Sol}(k+l) \end{aligned} \quad (80b)$$

$$\underline{P}_{Tur A} \leq P_{Tur A}(k+l) \leq \overline{P}_{Tur A} \quad (80c)$$

$$\underline{P}_{Tur B} \leq P_{Tur B}(k+l) \leq \overline{P}_{Tur B} \quad (80d)$$

$$\underline{P}_{CHP} \leq P_{CHP}(k+l) \leq K_d Bg_{in}(k+l) \quad (80e)$$

$$0 \leq P_{Cont}(k+l) \quad (80f)$$

$$K_a P_{Tur A}(k+l) + K_b P_{Tur B}(k+l) \leq \frac{K_c Bg_{in}(k+l)}{\alpha_A} \quad (80g)$$

$$OP_{Stoch} \triangleq \min_{\hat{P}_{Cont}} -\hat{P}_k \quad (81a)$$

$$\begin{aligned} \text{s.t. } P_{Dem}(k+l) + P_{Cont}(k+l) &= P_{Tur A}(k+l) \\ &+ P_{Tur B}(k+l) + P_{CHP}(k+l) \\ &+ P_{Wind}(k+l) + P_{Sol}(k+l) + \varphi_{DR}^{-1}(\delta) \end{aligned} \quad (81b)$$

$$\underline{P}_{Tur A} \leq P_{Tur A}(k+l) \leq \overline{P}_{Tur A} \quad (81c)$$

$$\underline{P}_{Tur B} \leq P_{Tur B}(k+l) \leq \overline{P}_{Tur B} \quad (81d)$$

$$\underline{P}_{CHP} \leq P_{CHP}(k+l) \leq K_d Bg_{in}(k+l) \quad (81e)$$

$$0 \leq P_{Cont}(k+l) \quad (81f)$$

$$K_a P_{Tur A}(k+l) + K_b P_{Tur B}(k+l) \leq \frac{K_c Bag_{in}(k+l)}{\alpha_A} - \varphi_{DB}^{-1}(\delta) \quad (81g)$$

Nas equações (80)-(81),  $k$  é o dia atual,  $P_{Cont}$  representa a energia produzida a cada instante,  $P_{Dem}$  representa o demanda elétrica de processo,  $P_{Tur A}$  e  $P_{Tur B}$  representam a produção das turbinas de maior e menor eficiência, respectivamente,  $P_{CHP}$  representa a produção de CHP,  $P_{Wind}$  é a produção de turbinas eólicas,  $P_{Sol}$  representa a produção de painéis fotovoltaicos,  $Bag_{in}$  é a entrada do bagaço e  $Bg_{in}$  do biogás. A produção de energia a partir de fontes renováveis é tomada como sendo proporcional ao valor da irradiação e da velocidade do vento e, da mesma forma, a produção de energia a partir do CHP e das turbinas também são assumidas como uma função linear dos insumos de biomassa e biogás. As constantes  $K_a = 1/160$  e  $K_b = 1/85$  são os ganhos das turbinas de maior e menor eficiência, respectivamente, sendo que  $K_c$  é o ganho da caldeira de alta eficiência,  $\alpha_A$  é o fator de mistura desta mesma caldeira,  $K_d = 0,37$  é o fator de conversão de biogás,  $\varphi_{DR}^{-1}$  é a CDF inversa para os erros de predição da potência diária gerada pelas fontes renováveis (vento e solar somados),  $\varphi_{DB}^{-1}$  é a CDF inversa relativa à entrada diária de bagaço e  $\delta$  é o risco aceitável de violação de restrição.

É importante notar que o horizonte de predição do controlador diminui à medida que passam os dias, assim  $l = 1 \dots \min[N, 30 - hoje]$ , sendo *hoje* o dia atual.

Com respeito à decisão da quantidade mensal de energia a ser produzida, a máquina de estados FSM, responsável por tal decisão, leva em conta as seguintes premissas: se a variável  $P_{Cont}$  fornecida pela solução do Problema de Otimização ( $OP$ ) não puder alcançar uma produção de final de mês maior que  $2\chi - \psi$ , ou seja,  $\hat{P}_k < (2\chi - \psi)$ , a FSM indica o *setpoint* de  $1\chi$  ( $SP_{FSM} = 1\chi$ ). Se a solução do  $OP$  estiver dentro de  $(2\chi - \psi) \leq \hat{P}_k < (2\chi + \psi)$ , a FSM fornecerá  $2\chi$  como *setpoint* ( $SP_{FSM} = 2\chi$ ); e se  $\hat{P}_k \geq (2\chi + \psi)$ , o FSM oferece um *setpoint* de  $2,3\chi$  ( $SP_{FSM} = 2,3\chi$ ). A Figura 36 explica a lógica da FSM.

A FSM está sendo denominada de *FSM-ótima*, uma vez que o cálculo da estimativa de produção de energia no final do mês ( $\hat{P}_k$ ) é obtido através da resolução de um problema



de otimização de programação quadrática, como apontado pelas equações (80) e (81), para as condições determinísticas e estocásticas, respectivamente.

No entanto, é possível que, eventualmente e devido a erros de previsão, o sistema encerre a produção mensal de energia na região indesejada do contrato, condição esta que é minimizada pela abordagem estocástica que considera os erros de previsão de maneira probabilística. Esta técnica resulta em uma abordagem mais conservadora, como será ilustrado nos estudos de simulação da seção 5.4.

**Observação:** Eventuais chaveamentos indesejáveis entre os estados são evitados naturalmente devido à dinâmica lenta do processo de geração de energia e ao período de amostragem escolhido (24h), enquanto que a unidade de controle do nível inferior opera a cada hora, como poderá ser visto na próxima seção.




Figura 36 – Sistema de Supervisão e de Tomada de Decisão Proposto

### 5.3.3 Camada de Controle

Nas seções anteriores foi detalhado como as estimativa das perturbações e as camadas de supervisão e decisão do processo funcionam. Nesta subseção explica-se como a camada de controle opera.

A camada de controle é composta por um MPC, cujo objetivo é otimizar as demandas do processo. O controlador MPC proposto trabalha com tempo de amostragem  $\Delta T = 1 h$  e usa dados de estimativas futuras de velocidade do vento e irradiação solar. O controlador tem como objetivo minimizar a função custo

$$J_{MPC} = \sum_{l=0}^{N_c-1} \left\| \text{Pot}_{Net}(k+l) - \frac{(SP_{FSM} - APE)}{T_{left}} \right\|_{Q_p}^2 + \sum_{l=0}^{N_c-1} q_u \hat{u}(k+l) + \sum_{l=0}^{N_p-1} \|\hat{x}(k+l) - \hat{x}_{ref}(k+l)\|_{Q_x}^2 + \sum_{l=0}^{N_p-1} q_e \epsilon(k+l) \quad (82)$$

onde  $q_u$  é um vetor definido positivo;  $Q_p$  e  $Q_x$  são matrizes de ponderação definidas positivas;  $APE$  representa a energia elétrica que já foi produzida pela microrrede no instante  $k$ ;  $SP_{FSM}$  representa o *setpoint* de produção de energia fornecido pelo FSM;  $T_{left}$  representa o tempo restante em horas até o final do mês;  $\hat{x}_{ref}$  é a referência para o vetor de estado do sistema;  $N_p = 12h$  representa o horizonte de previsão, enquanto  $N_c = 5h$  representa o horizonte de

controle e  $\epsilon$  é uma variável de folga. Como pode ser visto, o termo  $(SP_{FSM} - APE)$  representa quanta energia elétrica a microrrede ainda precisa produzir até o final do mês devido à exigência do contrato. Para isso, ao minimizar  $[Pot_{Net}[k + l] - \frac{(SP_{FSM} - APE)}{T_{left}}]$ , o controlador principal adapta a produção de energia no instante  $k$ , buscando sempre cumprir a meta de produção mensal de forma que até o final do mês a produção de energia elétrica fornecida à rede seja igual à definida pelo contrato.

Como já foi dito anteriormente, quando o controlador MPC está sujeito a perturbações estocásticas surge o problema do atendimento das restrições do próprio problema de otimização. Para enfrentar essa dificuldade, neste trabalho utiliza-se a técnica das restrições probabilísticas, ou *chance constraints*, separando as restrições que envolvem as perturbações em duas partes, sendo uma determinística e outra estocástica. O Problema de Otimização  $OP_{MPC}$  com as restrições determinísticas é dado por

$$OP_{MPC} \triangleq \min_u J_{MPC} \quad (83a)$$

$$\text{s.t. } x(k + l + 1) = Ax(k + l) + Bu(k + l) + Cq(k + l)$$

$$Dem(k + l) = Dx(k + l) + Eu(k + l) + Fq(k + l) \quad (83b)$$

$$\underline{x} \leq \hat{x}(k + l + 1) \leq \bar{x} \quad (83c)$$

$$\underline{u} \leq \hat{u}(k + l) \leq \bar{u} \quad (83d)$$

$$0 \leq \epsilon(k + l) \quad (83e)$$

$$0 \leq Pot_{Net}(k + l) \leq \frac{(SP_{FSM} - APE)}{T_{left}} + \epsilon(k + l) \quad (83f)$$

para  $l = 0, \dots, N_p - 1$ , sendo  $Dem$  as demandas do processo. A notação  $(\hat{a})$  é usada para variáveis em instantes futuros do horizonte de predição;  $\underline{a}_j$  e  $\bar{a}_j$  denota os valores mínimos e máximos permitidos para  $a$ . Em (82),  $Q_p$  é ajustado para que a produção de energia elétrica seja priorizada;  $Q_x$  é usado para manter os valores do vetor de estado do sistema perto de uma região referenciada de 50% de todos os estoques. O vetor  $q_u$  é utilizado para que a produção de energia seja proveniente, preferencialmente, da fonte de energia mais eficiente e sustentável. É importante observar que o modelo usado pelo controlador para calcular  $u$  é baseado em (71), sendo  $q$  a representação das perturbações estimadas.

Neste trabalho, a incerteza sobre a irradiação solar e as previsões de velocidade do vento foram consideradas para formular as restrições probabilísticas. Como os distúrbios estocásticos atuam diretamente sobre a demanda elétrica, no problema de otimização  $OP_{MPC}$  tal demanda é substituída pela restrição estocástica

$$P_{Dem}(k + l) + Pot_{Net}(k + l) = SP_{TU}^A(k + l) + SP_{TU}^B(k + l) + SP_{CHP}(k + l) + Pot_{Bat}(k + l) + P_{Wind}(k + l) + P_{Sol}(k + l) + \varphi_{HR}^{-1}(\delta) \quad (84)$$

sendo  $\varphi_{HR}^{-1}(\delta)$  a CDF inversa para os erros de previsão da potência de hora em hora gerada pelas fontes renováveis, calculada para o risco aceitável de violação de restrição  $\delta$ .

## 5.4 RESULTADOS

Esta seção apresenta os resultados de simulação da estratégia de controle hierárquico proposto, aplicado à microrrede da usina de cana-de-açúcar descrita anteriormente. A camada de decisão MPC e FSM foram implementadas usando o software *Matlab* (MATHWORKS, 2009) com a toolbox *Yalmip* (LOFBERG, 2004), utilizando o *CPLEX* como solver (ILOG, 2007). O tempo computacional médio para a camada de FSM é de 0,07 s e para a camada de MPC é de 0,03 s. Esses resultados vêm de simulações feitas em um PC com um processador Intel i7 (2.4 GHz, 8 GB RAM).

Deve-se ter em mente que os objetivos de controle são maximizar o uso de fontes de energia renováveis, garantir a produção de energia definida pelo contrato e garantir o atendimento das demandas em todos os instantes de tempo. Os resultados demonstram que houve realmente o uso das fontes renováveis cumprindo sempre o contrato de venda de energia.


Nesta seção serão apresentados os resultados divididos em três diferentes cenários com o intuito de deixar evidentes as vantagens da estratégia de controle proposta que utiliza a abordagem das restrições probabilísticas juntamente com a estimação das perturbações e uma camada de supervisão e decisão superior (FSM).

O primeiro cenário é mostrado na Figura 37a e representa uma entrada de cana-de-açúcar quase constante com níveis considerados altos, que é chamado de Cenário Alto. O segundo cenário, apresentado na Figura 37b, apresenta uma queda na entrada de cana-de-açúcar no final do mês e, portanto, é chamado de Cenário Médio. O último cenário representa um caso no qual a entrada de cana-de-açúcar diminui consideravelmente no final do mês e, por tanto, denomina-se Cenário Baixo e é mostrado na Figura 37c. É importante lembrar que a entrada de bagaço na usina é proporcional à entrada da cana-de-açúcar.


A Figura 38 mostra a irradiação, a velocidade do vento e a entrada de biogás na usina, sendo que estes não variam entre os cenários, enquanto que a Figura 39 mostra as demandas do processo.

A seguir, alguns resultados da simulação são discutidos. Para comparar o desempenho da metodologia proposta, todos os cenários serão aplicados a três casos com diferentes níveis de informação em relação a perturbações futuras: a) sem qualquer informação, chamado caso sem previsão, b) apenas com a informação de previsão, chamado caso com previsão e c) com estimativa de previsão e considerando o erro do estimador (que permite usar a estrutura das restrições probabilísticas), chamado caso de previsão-CC. Todas as nove possibilidades que englobam os cenários e casos são mostrados na Tabela 11.


Primeiramente, são analisados os resultados da produção de energia considerando o primeiro cenário de colheita da cana-de-açúcar (Figura 37a). A receita de biomassa é constante e a planta de processamento inicia sua operação na capacidade máxima de moagem. Os resultados da simulação, apresentados na Figura 40, retratam a energia gerada considerando os diferentes conhecimentos de estimação de perturbações futuras. Como pode ser visto, todos os casos neste primeiro cenário apresentam um desempenho final semelhante, permitindo que



(a) Cenário Alto (1)




(b) Cenário Médio (2)




(b) Cenário Baixo (3)


Figura 37 – Diferentes Cenários de Entrada de cana-de-açúcar



(a) Velocidade do Vento




(b) Irradiância




(c) Entrada de Biogás


Figura 38 – Perturbações: Velocidade do vento, irradiância e entrada de biogás




(a) Demanda de Energia



(b) Demanda de Vapor - média pressão



(c) Demanda de Vapor - baixa pressão



(d) Demanda de água fria

Figura 39 – Demandas do processo

Tabela 11 – Diferentes casos considerando os cenários de entrada de cana-de-açúcar

Cases	Cenário 1 (Alto)	Cenário 2 (Médio)	Cenário 3 (Baixo)
Caso sem previsão	Figura 40a	Figura 41a	Figura 42a
Caso com previsão	Figura 40b	Figura 41b	Figura 42b
Caso com previsão-CC	Figura 40c	Figura 41c	Figura 42c


a usina produza  $2,3\chi$ .

No segundo cenário (Figura 37b) o volume de entrada de cana colhida é menor do que a do primeiro cenário. Neste cenário, a entrada de biomassa diminui ao final do mês, consequentemente reduzindo a capacidade de geração de energia. Os resultados da geração de energia para os tres casos são mostrados na Figura 41, onde se pode ver que, nos casos em que há informação futura das perturbações, o sistema consegue evitar a região de penalidade, enquanto que o caso sem previsão cai nessa região indesejada. Por outro lado, a abordagem estocástica consegue tomar a decisão de mudar o *setpoint* de contrato antecipadamente, já que a abordagem probabilística agrega informação do comportamento futuro do erro de predição. Tal diferença torna o sistema, de certa forma, mais conservador se comparado com a solução determinística anterior.


O terceiro e último cenário, no qual tem-se baixa entrada de cana-de-açúcar (Figura 37c), principalmente no final do mês, representa um cenário de final de colheita em que a capacidade de geração fica reduzida. Ainda assim, deseja-se alcançar ao menos  $\chi$  de energia produzida, que equivale ao valor mínimo do contrato. Na Figura 42 podem ser vistos os resultados da simulação da geração de energia para os três casos. É notável que o caso sem previsão não pôde evitar a região de penalidade pela ausência de informações futuras. O caso com previsão também não pôde evitar a região de penalidade causada pelo erro do estimador. Finalmente, no caso com previsão-CC o controlador foi capaz de tomar a melhor decisão, evitando a região de penalidade por ter a informação do erro do preditor através da sua Função Densidade de Probabilidade. Desta forma, o controlador decide produzir apenas  $\chi$  com 90% de probabilidade de não atingir a região de penalização. Em outras palavras, ao utilizar as restrições probabilísticas, o risco de geração de energia estar fora das zonas obrigatórias ou lucrativas é de  $\delta = 10\%$ .

## 5.5 COMENTÁRIOS FINAIS DO CAPÍTULO


Apresentou-se neste capítulo uma abordagem de controle avançado baseada em uma estrutura hierárquica para o gerenciamento da geração de energia em uma unidade de processamento de cana-de-açúcar, onde utilizam-se diversas fontes renováveis de energia. Ainda, foram novamente usadas as chamadas restrições probabilísticas para enfrentar a incerteza das perturbações, cuja predição é feita usando Redes Neurais. O sistema de decisão proposto como camada superior FSM permite operar com regras de contrato de geração de energia e a camada



(a) Caso sem previsão



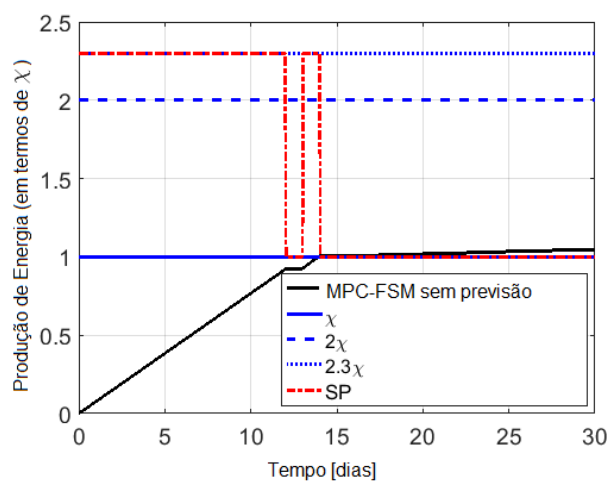
(b) Caso com previsão




(c) Caso com previsão-CC

Figura 40 – Resultados de Simulação: Primeiro cenário (Alta entrada de cana-de-açúcar)






(a) Caso sem previsão




(b) Caso com previsão




(c) Caso com previsão-CC


Figura 41 – Resultados de Simulação: Segundo cenário (Entrada de cana-de-açúcar alta)



(a) Caso sem previsão



(b) Caso com previsão



(c) Caso com previsão-CC

Figura 42 – Resultados de Simulação: Terceiro cenário (Baixa entrada de cana-de-açúcar)

inferior utiliza um controlador preditivo (MPC) para a otimização da produção de energia.

As simulações feitas para diversos casos de entrada de cana-de-açúcar e erros de estimação apresentaram resultados satisfatórios que comprovam o desempenho superior da abordagem proposta, visto que o sistema maximiza a geração de energia e a utilização das fontes renováveis, minimizando as penalizações pelo não atendimento do contrato de venda de energia.

O uso de restrições probabilísticas, principalmente no que diz respeito a sistemas que utilizam previsões das fontes de energia renovável, oferecem uma abordagem interessante quando comparado aos métodos determinísticos, pois minimizam o risco de violar restrições apesar de resultar em uma abordagem sub-ótima, ou seja, mais conservadora. No caso da usina de cana-de-açúcar, o uso da abordagem de restrições probabilísticas resultou no atendimento integral das restrições do processo.

Como principal contribuição deste capítulo pode-se destacar a formulação de um caso de estudo baseado em dados reais de uma usina de cana-de-açúcar formulando um controlador MPC com restrições probabilísticas que utiliza estimativas das variáveis estocásticas envolvidas.

A abordagem proposta, embora tenha considerado a estocasticidade das fontes renováveis, não resultou em altos custos computacionais.

## 6 SISTEMA DE GESTÃO DE ENERGIA DE DUAS CAMADAS PARA MICRORREDES COOPERATIVAS NA INDÚSTRIA DE CANA-DE-AÇÚCAR

### 6.1 INTRODUÇÃO

Neste capítulo será apresentado o projeto de um Sistema de Gerenciamento de Energia (EMS) com fontes renováveis envolvendo várias microrredes cooperando entre si. O tema é relevante para a indústria em geral, uma vez que é comum observar que um único operador gerencia várias pequenas unidades enquanto mantém um contrato fixo com a empresa local de distribuição de energia. Investir na operação de microrredes cooperativas com fontes de energia renovável pode ser uma alternativa para aumentar a participação desse tipo de fontes.

Como foi visto no capítulo anterior, o tema de como gerenciar e operar microrredes autônomas (isoladas) envolvendo fontes renováveis de energia é um tema que vem sendo estudado nos últimos anos. Muitos trabalhos enfrentaram essa temática, projetando controladores e desenvolvendo Sistemas de Gerenciamento de Energia com base em uma variedade de abordagens.

Em contrapartida, vários estudos comparativos indicam que microrredes interconectadas podem alcançar melhor desempenho se comparado com o caso de microrredes autônomas (PARISIO *et al.*, 2017). Por outro lado, a literatura ainda carece de trabalhos que investiguem sobre o projeto de sistemas EMS para microrredes interconectadas. O estado-da-arte da coordenação de microrredes interconectadas não é nulo, mas é limitado e em desenvolvimento. Os primeiros estudos datam da segunda metade da década de 10 (KATIRAEI; IRAVANI, 2006), enquanto que as primeiras iniciativas sobre compartilhamento de carga e geração de energia cooperativa foram apresentadas por Majumder *et al.* (2009).

Pesquisas recentes (BULLICH-MASSAGUÉ *et al.*, 2018; BOUZID *et al.*, 2015) debatem os prós e contras de diferentes estratégias de coordenação de microrredes. Adicionalmente, Bui *et al.* (2018) empregam um esquema multi-agente hierárquico multi-dimensional; Song *et al.* (2015) apresentam o projeto utilizando controle sequencial; Mendes *et al.* (2017) apresentam um controlador MPC baseado em uma distribuição das microrredes considerando programação inteira mista e no trabalho de Felix Garcia-Torres *et al.* (2019) é discutido o projeto de outro controlador MPC distribuído; Grosso *et al.* (2014) apresentam um controlador preditivo concebido para a gestão de redes de água potável. Aplicações de compensação de ação *FeedForward* junto ao controlador MPC também foram vistas no trabalho de Oldewurtel *et al.* (2010). Uma estratégia de controle hierárquico baseada em otimização para gerenciamento otimizado de energia é proposta por Tavakoli *et al.* (2018) para a construção de microrredes com energia eólica e, muito recentemente, Legry *et al.* (2018) apresentaram um controlador MPC em duas camadas para o seguimento de parâmetros econômicos de microrredes isoladas. Minchala-Avila *et al.* (2015) e Shayeghi *et al.* (2019) são dois artigos de revisão (*reviews*) recentes que abordam métodos de controle ótimo aplicadas à gestão e controle de microrredes de energia.

No entanto, o projeto de sistemas centralizados de gerenciamento de energia ainda é a abordagem mais utilizada para microrredes isoladas, como pode ser visto no trabalho de Xu *et al.* (2015), Palizban e Kauhaniemi (2015), Xiao *et al.* (2015), Olivares *et al.* (2014) e Ouammi *et al.* (2015), sendo que o último trabalho opera várias microrredes com um esquema de controle MPC centralizado. Uma revisão das recentes estratégias centralizadas de compartilhamento de energia pode ser vista no trabalho de Han *et al.* (2016).

No que diz respeito ao projeto de controladores de energia robustos (ZHANG, B. *et al.*, 2018) que levam em conta a existência de incertezas estruturadas, a literatura mostra que, apesar dos resultados obtidos serem considerados adequados (embora às vezes sejam muito conservadores), são computacionalmente complexos, dificultando o seu uso em aplicações em tempo real. Assim, neste capítulo apresenta-se o uso de uma abordagem probabilística aplicada a sistemas de gerenciamento de energia sujeitos a incertezas que têm menor complexidade e permitem obter bons resultados.

O problema aqui apresentado é o de três usinas geradoras de energia (microrredes) pertencentes à mesma empresa que podem cooperar entre si e que obedecem a uma regra única de contrato de fornecimento de energia para a rede externa de energia. Ou seja, elas devem trabalhar juntas para atingir uma meta única de geração de energia. Considerando a literatura mais recente, uma provável solução é o projeto de um EMS centralizado (possivelmente hierárquico) para maximizar os lucros da empresa e atingir as metas de produção de energia<sup>1</sup>, sendo esta a abordagem a escolhida para o estudo de caso das três microrredes, cuja motivação principal é testar, discutir e avaliar o projeto hierárquico de sistemas EMS para microrredes cooperativas.

A principal contribuição deste trabalho é apresentar uma proposta de compartilhamento de recursos aplicada ao gerenciamento de energia para microrredes a partir de um nível de supervisão. O método hierárquico proposto pode ser estendido ao caso de várias microrredes, tendo como consequência o aumento linear do número das restrições. Esse esquema é composto de um sistema de Otimização em Tempo Real (RTO) que planeja a geração de energia pelas usinas locais e as regras para compartilhamento de recursos, enquanto que MPCs são projetados para o nível local, garantindo que os *setpoints* de geração de energia sejam alcançados.

É importante salientar que, apesar da pesquisa deste capítulo ter sido fruto do trabalho em conjunto de vários autores, a minha contribuição foi direcionada justamente ao sistema EMS, ou seja, à estrutura de controle que utiliza fundamentos da abordagem conhecida como RTO (*Real Time Optimization*), justamente a área que em que culminou o último trabalho desta tese, apresentado no capítulo 7.

<sup>1</sup> Observe-se que não há motivos para considerar métodos de controle distribuído para esse problema, uma vez que a mesma empresa possui todas as microrredes e pode tomar as decisões de forma centralizada.

## 6.2 FORMALIZAÇÃO DO PROBLEMA

### 6.2.1 Caso de Estudo

Neste trabalho considera-se um conjunto de três usinas de cana-de-açúcar localizadas em diferentes locais do estado de São Paulo, Brasil. Cada uma dessas microrredes é composta de turbinas a vapor alimentadas por caldeiras que queimam biomassa, um banco de baterias para compensar flutuações e painéis fotovoltaicos (PV). Tais elementos estão interconectados pela rede de energia e pelas rodovias (é possível transportar biomassa de uma usina para outra, conforme discutido em (MORATO, Marcelo M. *et al.*, 2019)). A Figura 43 exibe a estrutura dessas microrredes, enquanto que na Figura 44 é apresentada a disposição espacial aproximada dessas usinas. A distância dos canaviais para cada planta é negligenciada por ser considerada irrelevante diante da distância entre elas.

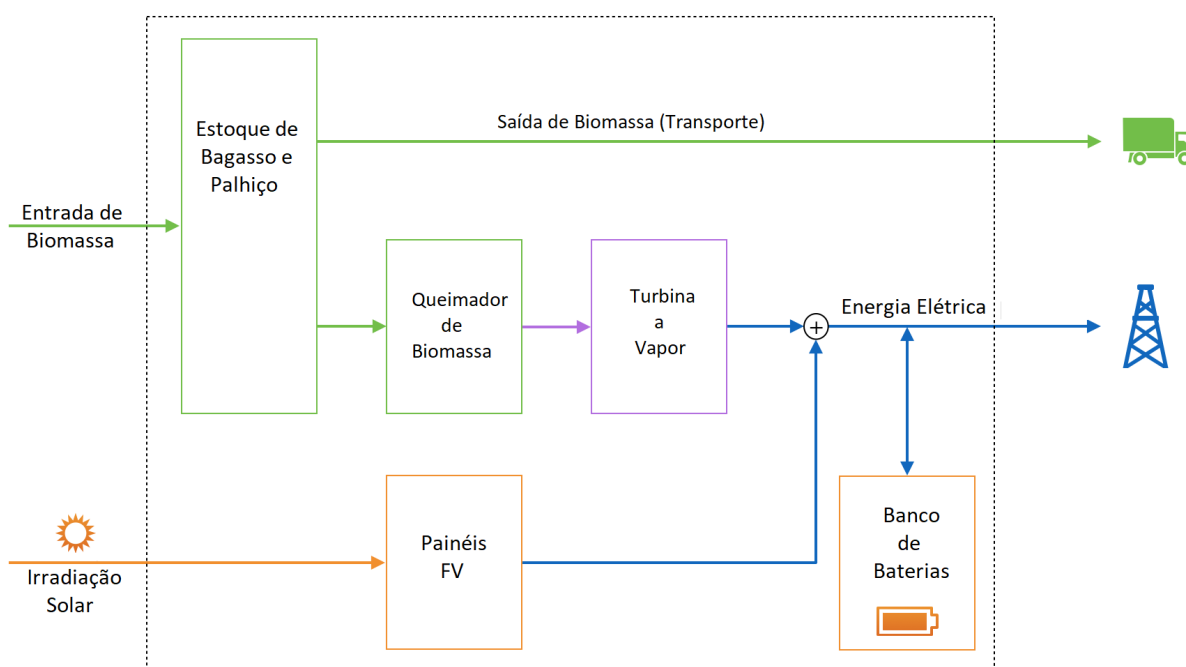


Figura 43 – Fluxo de energia das Microrredes

### 6.2.2 Objetivo de geração de energia

O problema enfrentado neste trabalho é o de como gerenciar as três microrredes de maneira coordenada para que a meta mensal de geração de energia seja sempre cumprida.

Cada usina - ou microrrede (Microrrede (MG)) - possui uma demanda interna de energia elétrica proveniente do processo de produção de etanol e açúcar que deve ser satisfeita. Ilustrativamente, a Figura 45 mostra um perfil de demanda de energia elétrica de uma usina de cana-de-açúcar no Brasil (MORATO, Marcelo Menezes *et al.*, 2018).

Além das demandas internas de cada MG, o grupo de usinas deve produzir uma determinada quantidade de energia elétrica para ser vendida ao distribuidor local de energia;



Figura 44 – Disposição das usinas (microrredes) envolvidas - São Paulo, Brasil.




Figura 45 – Perfil de demanda interna de energia elétrica de uma usina de cana-de-açúcar no Brasil

esta operação de venda é regida por um contrato entre as partes que estabelece o valor fixo de  $\Psi = 110 \text{ GWh}$  por mês<sup>2</sup>. Cada unidade de geração (MG) fornecerá à rede externa a sua sobra de energia produzida, podendo contribuir de forma diferente em cada momento do dia. É importante salientar que, segundo a própria legislação brasileira, a geração mensal de energia não precisa ser exatamente igual a  $\Psi$  por haver um fator de tolerância de  $\Psi = \pm 20\%$ .

**Observação 1.** A operação de microrredes pode ser investigada nos três níveis de controle hierárquico. Os problemas de instrumentação e comunicação são analisados em um primeiro nível. A operação local dos subsistemas é gerenciada no segundo nível, enquanto que o planejamento de energia é realizado no terceiro nível, ou nível terciário. Este trabalho está relacionado ao nível terciário, o que significa que um controlador supervisor determinará referências para cada um dos subsistemas da microrrede.

<sup>2</sup> Esses valores foram obtidos de dados reais de uma indústria de processamento de cana do estado de São Paulo, parceiro de pesquisa dos autores.

Cada MG, representada pelo super-índice  $j$ , é descrita por três estados (em tempo discreto): o nível normalizado de energia nos bancos de baterias  $x_1^j$ , o nível normalizado de biomassa de bagaço mais estoque de palhiço  $x_2^j$  e a quantidade total de energia produzida pela MG (acumulada),  $x_3^j$  (vendida ao distribuidor da rede e usada em demandas internas). A MG é “perturbada” pela irradiação solar presente nos canaviais  $I$ , dada em  $\frac{W}{m^2}$ , e pela entrada de biomassa  $Bm$  (palhiço e bagaço) proveniente do campo, dado em  $\frac{Mg}{h}$  (ou seja, tonelada por hora); essas duas variáveis compõem as perturbações  $w$ . As entradas de controle, ou seja, variáveis manipuladas, são os *setpoints* determinados pelos controles superiores: o *setpoint* de geração de energia da caldeira e turbina  $u_{BT}$ , o *setpoint* do fluxo de entrada/saída de energia do banco de baterias  $u_{Bat}$  e o transporte de biomassa de cada usina para as outras duas  $u_{j \rightarrow i}$  ( $j$  representa a MG em questão,  $\rightarrow$  define a direção do transporte e  $i$  representa a MG de destino).

Considerando que uma usina pode precisar comprar energia da rede<sup>3</sup>, neste projeto foi considerada a variável  $u_{Buy}^j$  que é introduzida para indicar a energia consumida da rede, fornecida em  $kW$ . Em uma operação dita normal essa variável deve ser levada a zero pelo controlador, sempre que possível.

Do ponto de vista matemático, a dinâmica dos estoques  $x_1^j$  e  $x_2^j$  é bastante simples, uma vez que são (idealmente) integradores<sup>4</sup>

$$x_1^j(k+1) = \sigma_1^j x_1^j(k) + \left( \epsilon_{in_1}^j u_{in_1}^j(k) - \epsilon_{out_1}^j u_{out_1}^j(k) \right) \Delta T \quad (85)$$

$$x_2^j(k+1) = \sigma_2^j x_2^j(k) + \left( \epsilon_{in_2}^j u_{in_2}^j(k) - \epsilon_{out_2}^j u_{out_2}^j(k) \right) \Delta T \quad (86)$$

onde  $u_{in}$  e  $u_{out}$  representam, respectivamente, fluxos de entrada e saída genéricos para esses estoques e os pesos  $\sigma_j$  representam a perda de energia interna de um instante de amostragem para o seguinte. A eficiência energética de cada ação é representada pelos parâmetros  $\epsilon_{in}^j$  e  $\epsilon_{out}^j$ .

**Hipótese 1.** Para simplificar o procedimento de modelagem, presume-se que os bancos de baterias tenham eficiência igual ao serem carregados ou descarregados, ou seja,  $\epsilon_{in_1}^j = \epsilon_{out_1}^j = \epsilon_{Bat}^j$ . Além disso, presume-se que o estoque de biomassa não tenha perdas ao estocar bagaço e palhiço, ou seja,  $\epsilon_{in_2}^j = \epsilon_{out_2}^j = 1$ .

Considerando as três microrredes, com  $j = A, B, C$ , os seguintes vetores discretos são

<sup>3</sup> De fato, isso ocorre no período em que não há colheita, mas este capítulo se concentra apenas na operação no período de colheita dessas usinas.

<sup>4</sup> Somadores



definidos:

$$x^j(k) = \left[ x_1^j(k) \ x_2^j(k) \ x_3^j(k) \right]^T, \quad (87)$$

$$w^j(k) = \left[ l^j(k) \ Bm^j(k) \right]^T, \quad (88)$$

$$u^j(k) = \left[ u_{Bat}^j(k) \ u_{BT}^j(k) \ u_{Buy}^j \right]^T, \quad (89)$$

$$u_{out}^j(k) = \left[ u_{j \rightarrow i}(k) \ u_{j \rightarrow m}(k) \right]^T, \quad (90)$$

$$u_{in}^j(k) = \left[ u_{i \rightarrow j}(k) \ u_{m \rightarrow j}(k) \right]^T, \quad (91)$$

onde  $x^j$  é o vetor dos estados da MG  $j$ ,  $w^j$  é o vetor de perturbações nos canais da MG  $j$ ,  $u^j$  os setpoints de supervisão relacionados à geração de energia na MG  $j$ ,  $u_{out}^j$  são os setpoints do transporte de biomassa da MG  $j$  para a MG  $i$  e  $m$  e, por último,  $u_{in}$  a entrada de biomassa das outras duas microrredes para  $j$ .

**Hipótese 2.** *Todos os estados são mensuráveis. Portanto, considera-se  $y^j = x^j$  como as saídas medidas de cada MG. Observe que isso não é um absurdo, uma vez que, na prática, os níveis de estoque são mensuráveis e a quantidade de energia produzida também.*

**Hipótese 3.** *O transporte de biomassa (bagaço e palhiço) de um MG para as outras duas é feito através do carregamento de caminhões. Atualmente, o transporte no Brasil é feito quase que exclusivamente em rodovias e por caminhões. Portanto, supõe-se que esses fenômenos ocorram em velocidade quase constante, o que leva a uma quantidade fixa de tempo de transporte de uma MG para outra, de acordo com as distâncias indicadas na Figura 44.*

Dada a Hipótese 3, existirá um atraso de transporte fixo (tempo morto) do ponto de vista de uma MG para a outra. Esses atrasos, dados em períodos de amostragem discretos, são:  $\delta_{AB}$ ,  $\delta_{AC}$  e  $\delta_{BC}$ , com  $\delta_{AC} > \delta_{AB} > \delta_{BC}$ . Obviamente, existe um custo associado a esse transporte de biomassa. Esses valores incluem o transporte de biomassa e o carregamento dos caminhões.

A partir do desenvolvimento acima e atendendo ao descrito por Geidl *et al.* (2007), o seguinte modelo em espaço de estados surge para cada MG  $j$  com relação às outras duas microrredes  $i$  e  $m$

$$\begin{aligned}
 x^j(k+1) = & \overbrace{\text{diag}\{\sigma_1^j \quad \sigma_2^j \quad 1\}}^{A^j} x^j(k) + \overbrace{\begin{bmatrix} 0 & 0 \\ 0 & 1 \\ \xi_{PV}^j & 0 \end{bmatrix}}^{B_1^j} w^j(k) \\
 & + \overbrace{\begin{bmatrix} -\epsilon_{Bat}^j & 0 & 0 \\ 0 & -\frac{1}{\xi_{BT}^j} & 0 \\ 1 & 1 & 1 \end{bmatrix}}^{B_2^j} u^j(k) + \overbrace{\begin{bmatrix} 0 & 0 \\ -1 & -1 \\ 0 & 0 \end{bmatrix}}^{B_{out}^j} u_{out}^j(k) \\
 & + \overbrace{\begin{bmatrix} 0 & 0 \\ 1 & 0 \\ 0 & 0 \end{bmatrix}}^{B_{in_i}^j} u_{in}^j(k - \delta_{ji}) + \overbrace{\begin{bmatrix} 0 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix}}^{B_{in_m}^j} u_{in}^j(k - \delta_{jm}) .
 \end{aligned} \tag{92}$$

Os parâmetros das três microrredes consideradas são apresentados na Tabela 12. Esta tabela mostra que a MG “A” possui uma unidade de geração de queima de biomassa com maior capacidade, sendo esta mais eficiente do que as outras duas plantas, o que resulta em um valor maior de  $\xi_{BT}^j$ . Este parâmetro descreve o fluxo de saída dos estoques de biomassa, relacionando  $u_{BT}^j$  a  $x_2^j$ , que é, de fato, o inverso do ganho do fluxo de energia de cada caldeira/turbina. Todos os bancos de baterias têm a mesma eficiência de carregamento / descarregamento, enquanto que a perda de massa nos estoques de biomassa varia. Na prática, o fator  $\sigma_2^j$  depende do tamanho das unidades de acúmulo de biomassa: a biomassa é “perdida” devido à chuva que molha parte da biomassa desprotegida, tornando-a inutilizável.

Cada usina tem limites para as suas variáveis controladas e manipuladas. As restrições operacionais de cada usina são apresentadas na seguinte seção.

Tabela 12 – Parâmetros das Microrredes

	MG A		MG B		MG C
$\sigma_1^A$	0.99	$\sigma_1^B$	0.99	$\sigma_1^C$	0.99
$\sigma_2^A$	0.83	$\sigma_2^B$	0.87	$\sigma_2^C$	0.95
$\xi_{PV}^A$	80 hm <sup>2</sup>	$\xi_{PV}^B$	80 hm <sup>2</sup>	$\xi_{PV}^C$	80 hm <sup>2</sup>
$\xi_{BT}^A$	0.253 $\frac{\text{mWh}}{\text{g}}$	$\xi_{BT}^B$	0.195 $\frac{\text{mWh}}{\text{g}}$	$\xi_{BT}^C$	0.180 $\frac{\text{mWh}}{\text{g}}$
$\epsilon_{Bat}^A$	0.93	$\epsilon_{Bat}^B$	0.93	$\epsilon_{Bat}^C$	0.93

Observe que as unidades para os fatores de conversão  $\xi$  na Tabela 12 surgem devido ao produto da unidade de medição de fluxo de saída pelo inverso da unidade de medição de

fluxo de entrada. Por exemplo,  $(\xi_{PV}^j)(\mu^j) = (x_3^j)$ , o que significa unidade  $\{\xi_{PV}^j\} = \text{unidade } \left\{ \frac{x_3^j}{\mu^j} \right\} = \frac{Wh}{\frac{W}{m^2}} = hm^2$ .

### 6.2.3 Restrições Operacionais

A Tabela 13 mostra as informações técnicas sobre as três microrredes. A colheita e a operação de “A” são superiores às outras duas, assim como sua produção média de etanol e açúcar (o que leva a maiores demandas elétricas internas). As distâncias entre essas plantas estão representadas no mapa da Figura 44: “B” a “C” : 50 km; “A” a “B” : 90 km; “A” a “C” : 125 km. Isso leva aos seguintes valores para os termos de atraso:  $\delta_{BC} = 1$ ,  $\delta_{AB} = 2$  e  $\delta_{AC} = 3$  (fornecido em amostras de  $\delta T = 1$  hora).

Além disso, são levados em conta 200 dias de colheita por ano, o que é considerado normal para uma usina no Brasil (MORATO, Marcelo Menezes *et al.*, 2018). Como as três usinas estão localizadas próximas uma da outra, seus valores médios (anuais) de irradiação solar são praticamente os mesmos, atingindo algo em torno de  $220 \text{ W/m}^2$ .

A proposta deste estudo de caso é que as três plantas tenham painéis fotovoltaicos cobrindo uma área de  $200 \text{ m}^2$  em cada uma, fornecidos pelo mesmo fabricante, com 15,85% de eficiência e  $1,8 \text{ MW}_{\text{pico}}$  (o que significa que eles produzem essa quantidade de energia no pico da irradiação solar). Além disso, as caldeiras e turbinas operam com as seguintes restrições operacionais de valores mínimos e máximos  $\Omega_{BT}^j$ , sendo

$$u_{BT}^A \in (15, 100) \text{ MW} \quad (93)$$

$$u_{BT}^B \in (10, 70) \text{ MW} \quad (94)$$

$$u_{BT}^C \in (9, 60) \text{ MW}. \quad (95)$$

A operação de cada banco de baterias ( $u_{Bat}^j$ ) também tem restrições operacionais dadas por

$$\Omega_{Bat}^j = (-30, 30) \text{ MW}. \quad (96)$$

## 6.3 ESTRUTURA HIERÁRQUICA PROPOSTA

Em geral, a indústria de processos usa critérios de otimização econômica nas formulações de controle dividindo o problema em camadas (FINDEISEN, Władysław, 1980; CAMPOS *et al.*, 2013). A estrutura proposta para enfrentar o problema detalhado na Seção 6.2.2 é um controlador hierárquico de duas camadas. Tal divisão é utilizada para que a camada superior (RTO) ocupe-se da coordenação das usinas em termos de planejamento de geração de energia, transporte de biomassa e rejeição a perturbações. Já, a camada inferior gerencia cada MG buscando seguir os setpoints repassados pela camada superior respeitando as restrições locais, garantindo que caldeiras/turbinas e painéis PV produzam energia de acordo com as necessidades.

Tabela 13 – Informações Técnicas das Microrredes

MG "A"	Média
Produção de Açúcar e Etanol	700 L/m <sup>2</sup> <sub>colhido</sub> , 1.5 Mg/h
Demanda Interna	13000 kW
Entrada de Bagasso e Palhiço	235 Mg/h
MG "B"	Média
Produção de Açúcar e Etanol	335 L/m <sup>2</sup> <sub>colhido</sub> , 0.6 Mg/h
Demanda Interna	8500 kW
Entrada de Bagasso e Palhiço	113 Mg/h
MG "C"	Média
Produção de Açúcar e Etanol	400 L/m <sup>2</sup> <sub>colhido</sub> , 0.45 Mg/h
Demanda Interna	7500 kW
Entrada de Bagasso e Palhiço	95.40 Mg/h

Neste trabalho, a camada superior RTO define o setpoint da operação levando em consideração os objetivos gerais do sistema, que são: custo de geração de energia elétrica, contrato de venda de energia para rede, compartilhamento e alocação de recursos (transporte de biomassa), bem como as demandas internas de cada usina. Normalmente, a camada RTO analisa um horizonte de previsão na ordem de meses e, devido à complexidade dos sistemas industriais, é comum que os modelos usados nessa camada de planejamento sejam complexos e simplificados (modelos estáticos), normalmente usando períodos de amostragem maiores, na ordem de horas ou dias. Adicionalmente, neste trabalho utiliza-se a compensação FF na camada de RTO, de acordo com as previsões futuras de irradiação solar.

Um esquema global do sistema é ilustrado, na Figura 46, usando diagramas de blocos. A camada superior (supervisória) resolve um problema de Otimização em tempo real (detalhado na Seção 6.4) que responde a um objetivo de geração de energia (geração mensal de  $\Psi$ , conforme discutido na Seção 6.2.2), tendo previsões de irradiação solar disponíveis. A camada inferior (Controladores locais em cada MG, Controlador Central da Microrrede (MGCC)s) representa um conjunto de controladores MPC (detalhados na Seção 6.5), os quais têm, também, informações das previsões de irradiação solar<sup>5</sup>.

#### 6.4 CAMADA SUPERIOR DE CONTROLE: RTO EMS

Esta seção explica o funcionamento da camada superior RTO ilustrada na Figura 46. Esta camada, chamada de RTO EMS, tem como missão coordenar a operação das três microrredes para atingir os objetivos técnico-econômicos do grupo todo, ou seja, da empresa proprietária das usinas. A coordenação em si representa a escolha dos pontos de operação (*setpoints*) adequados em termos de produção de energia (para cumprir o contrato mensal,  $\Psi$ ) e de compartilhamento de recursos (transporte de biomassa de uma usina para outra).

<sup>5</sup> Neste capítulo foi utilizada a mesma técnica de predição detalhada no capítulo 5.

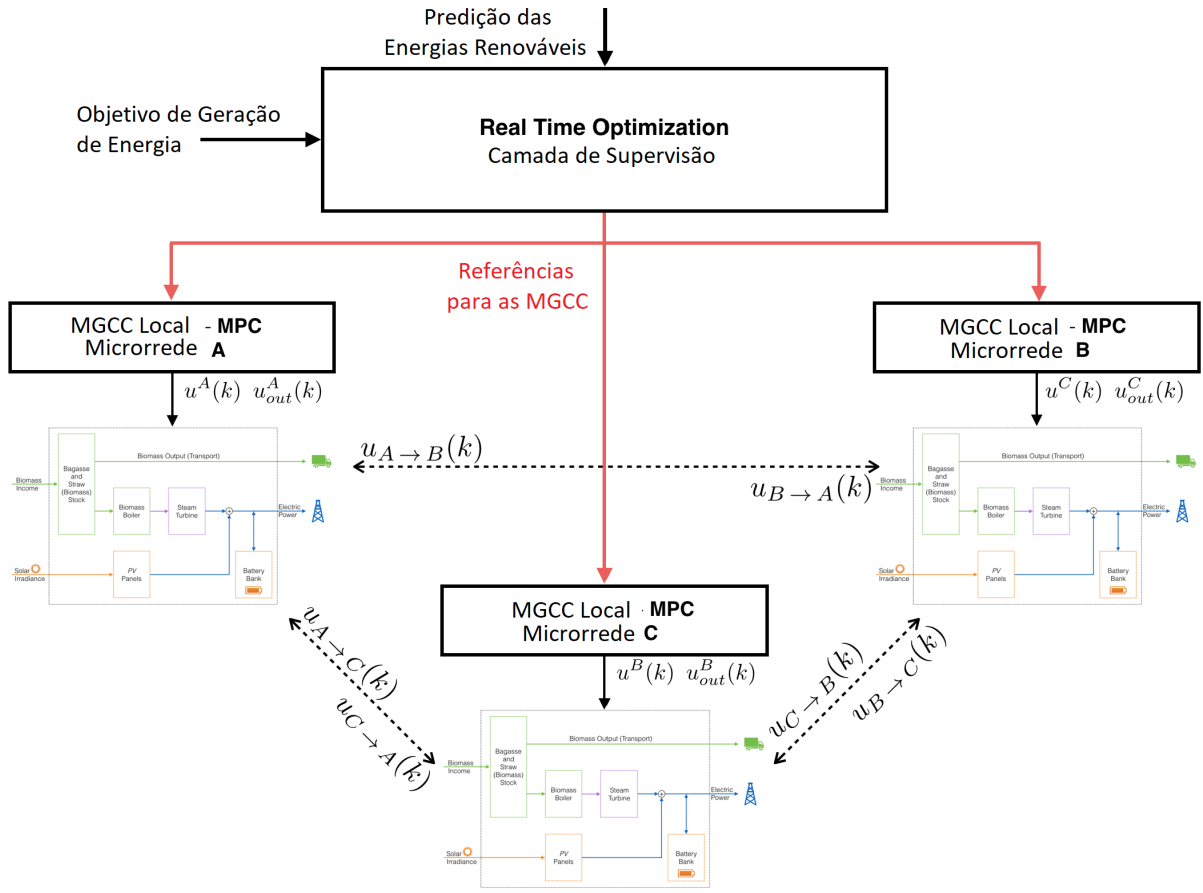


Figura 46 – Estrutura Hierárquica (EMS) Proposta

Portanto, considera-se que o RTO EMS determina as seguintes referências para o sistema

$$R(k) = \begin{bmatrix} R_A(k) & R_B(k) & R_C(k) \end{bmatrix}' , \quad (97)$$

$$R^{Bio}(k) = \begin{bmatrix} R_{A \rightarrow B}^{Bio}(k) & R_{A \rightarrow C}^{Bio}(k) & \dots \\ R_{B \rightarrow A}^{Bio}(k) & R_{B \rightarrow C}^{Bio}(k) & \dots \\ R_{C \rightarrow A}^{Bio}(k) & R_{C \rightarrow B}^{Bio}(k) \end{bmatrix}' , \quad (98)$$

$$R^I(k) = \begin{bmatrix} R_A^I(k) & R_B^I(k) & R_C^I(k) \end{bmatrix}' , \quad (99)$$

que devem ser repassadas, a cada instante  $k$  aos MGCCs de nível inferior. Cada  $R_j$  representa o *setpoint* de geração de energia;  $R_j^{Bio}$  o *setpoint* de transporte de biomassa (em número de caminhões) para as outras microrredes de  $j$ ; e  $R_j^I$  os *setpoints* de geração adicional de energia (nos casos de compensação de energia comprada da rede).

O cálculo da referência  $R$  deve ser coerente com a geração de energia elétrica  $\Psi$  a ser entregue para a a rede externa, bem como com as demandas internas de cada usina, conforme detalhado na seção 6.2.2.

### 6.4.1 Problema de Otimização

Neste trabalho, a camada de RTO proposta está configurada para operar a cada 12 horas<sup>6</sup>, como foi demonstrado no capítulo anterior. O RTO atualiza os *setpoints* todos os dias à meia-noite e ao meio-dia. Ele tem à sua disposição a estimativa da irradiação solar para os próximos quinze dias, conforme discutido no capítulo 5.

A camada inferior de controle avançado (MPC) é a responsável por estabelecer a melhor trajetória que as variáveis manipuladas podem cursar para atingir o ponto de operação da camada superior (RTO).

Do ponto de vista da camada superior, as três microrredes  $j$  são amostradas a cada  $T_{RTO} = 12\delta T$ . Portanto, a dinâmica de geração de energia e transporte de recursos das três microrredes pode ser vista a partir de  $T_{RTO}$ -instantes discretos  $k_2$  do ponto de vista de MG  $j$  e em relação às outras duas usinas  $m$  e  $i$ , da seguinte maneira:

$$x_3^j(k_2) = x_3^j(k_2 - 1) + P_{PV}^j(k_2) + P_{BT}^j(k_2), \quad (100)$$

$$P_{PV}^j(k_2) = \xi_{PV}^j I^j(k_2), \quad (101)$$

$$Bm_{in}^j(k_2) = \sum_{k=12(k_2-1)}^{12k_2} Bm^j(k), \quad (102)$$

$$Bm_{total}^j(k_2) = Bm_{in}^j(k_2) + \sigma_{tk} R_{m \rightarrow j}^{Bio}(k_2 - 1) + \sigma_{tk} R_{i \rightarrow j}^{Bio}(k_2 - 1), \quad (103)$$

$$P_{BT}^j(k_2) = \xi_{BT}^j Bm_{total}^j(k_2), \quad (104)$$

$$Bm_{used}^j(k_2) = \frac{1}{\xi_j^{BT}} \rho^j(k_2) R_j(k_2), \quad (105)$$

onde  $\rho^j(k_2)$  é uma variável contida em  $[0, 1]$  que indica a parcela da geração de energia de  $R^j$  que está sendo sustentada pela turbina/caldeira. A turbina a vapor suporta, se não houver irradiação solar (dia nublado), 100% da demanda de energia necessária (contrato e demanda interna), com  $\rho^j = 1$ .

Com respeito às equações (100) a (105), é importante salientar que:

- (i) Eq. (100) descreve a dinâmica do integrador dos estados  $x_3^j$ , no domínio discreto  $k_2$ . Este é o modelo de geração de energia para cada MG  $j$ .
- (ii) A variável de irradiação solar  $I^j$ , neste domínio discreto de  $k_2$ , é dada em termos de energia solar acumulada em um período de 12 horas. Eq. (101), portanto, fornece a

<sup>6</sup> Note-se esse período deve ser maior que o maior atraso  $\delta_{ji}$  (3 horas), para que os atrasos no transporte de biomassa não precisem ser levados em consideração nesse nível.

energia gerada pelos painéis fotovoltaicos  $P_{PV}^j$ .

- (iii) Eq. (102) descreve a biomassa proveniente dos canaviais a cada 12 horas, dada pela soma das entradas em cada hora dentro do período  $T_{RTO}$ .
- (iv)  $R_{j \rightarrow m}^{Bio}$  e  $R_{j \rightarrow i}^{Bio}$  representam os *setpoints* para o transporte de biomassa entre as microrredes (em número de caminhões, onde  $\sigma_{tk} = 35 \text{ Mg/caminhão}$  é a quantidade de biomassa (toneladas) por caminhão). Note-se que os atrasos de transporte nessas variáveis não precisam ser levados em consideração na Eq. (103), pois são menores que 12 horas. Portanto, esta equação está relacionada à entrada total de biomassa em MG  $j$ . Adicionalmente, os *setpoints* de transporte de biomassa estabelecidos pelo RTO devem ser seguidos dentro de um período de amostragem de  $T_{RTO}$  (que será uma restrição para o problema de otimização dos MGCCs).
- (v) A eq. (104) descreve a energia gerada pelas turbinas/caldeiras a cada instante  $k_2$ ;  $\xi_{BT}^j$  representa a relação de transformação da biomassa em energia para cada turbina/caldeira e  $Bm_{total}^j$  é a quantidade total de biomassa.
- (vi) A quantidade total de biomassa queimada localmente em MG  $j$  é descrita pela Eq. (105), sendo que  $\rho_j$  indica a quantidade de energia produzida para atendimento do contrato pela turbina/caldeira.
- (vii) Note-se que a variável  $\rho^j(k_2)$  não é conhecida, mas é intrinsecamente limitada em 1, o que representa diretamente o total da biomassa (queimada) usada na usina  $j$  a cada instante de amostragem  $k_2$ , ou seja,  $Bm_{usada}^j(k_2)$ , cujo valor máximo é limitado.
- (viii) Obviamente, existe um custo associado ao transporte da biomassa. Esse custo é fixo e dado pela distância percorrida<sup>7</sup>, estimada em R\$15,00 por tonelada (Mg) de biomassa carregada, por hora de transporte percorrido. Exemplo: o custo do transporte de “A” para “C” é de R\$ 45,00 por tonelada, R\$ 30,00 de “A” para “B”, enquanto que de “B” a “C” custa R\$ 15,00 por tonelada (e *vice-versa*, ou seja, o mesmo custo no sentido contrário).
- (ix) Além disso, há um custo associado à queima de biomassa em cada usina  $j$ . Deve-se observar que o custo de queima local está correlacionado com o custo de manutenção e operação das caldeiras e turbinas. Uma análise de custo (*payback*) dessa operação e manutenção (*O&M*) dessas usinas da indústria de cana é apresentada em (MORATO, Marcelo Menezes *et al.*, 2018). Tais taxas são, aproximadamente, proporcionais à média da biomassa queimada e, por esse motivo, plantas mais eficientes (que precisam queimar menos biomassa para produzir a mesma quantidade de energia) têm menor custo de *O&M* associados. Percebe-se que a MG “A”, por ter uma turbina mais eficiente (consulte

<sup>7</sup> Veja Hipótese 3

a Tabela 12, onde  $\frac{1}{\xi_{BT}^j}$  é o inverso do ganho de biomassa em energia), é a MG que tem menor custo de *O&M*. Os custos de *O&M* são estimados em: MG “A” R\$ 17,00 por tonelada; MG “B” R\$ 25,00 por tonelada; MG “C” R\$ 27,00 por tonelada (incluem custo da mão-de-obra, preço do diesel, dentre outros). Levando isso em consideração, o *RTO EMS* deve decidir se é rentável transportar biomassa excedente para outra planta ( $m$  ou  $i$ ) ou queimá-la localmente em  $j$ . Isso deve levar em consideração a eficiência de cada unidade turbina/caldeira e o custo do transporte.

Para o problema estudado, o *RTO EMS* possui uma função de custo dividida em duas partes: uma que trata do gerenciamento de energia e outra que trata do problema de compartilhamento de recursos de biomassa. Eles são explicados individualmente a seguir.

A função de custo relacionada ao gerenciamento de energia é bastante direta, pois visa garantir que, ao final do mês ( $N_{RTO} = 30$  dias = 60 amostras de  $T_{RTO}$ ), a energia contratada (somada com as demandas) seja produzida pela soma da produção das três microrredes, dado por

$$J_{RTO}^{\Psi} = \left\| \begin{array}{l} \text{objetivo total-energia} \\ (\sigma + \Psi + \Psi_D) \end{array} - \underbrace{\text{produção total}}_{\Psi_{k_2}^{total}} \right\|^2, \quad (106)$$

$$\Psi_{k_2}^{total} = \left( \Psi_{k_2} + \sum_{n=1}^{N_{RTO}-k_2} \sum_{j=A}^C x_3^j(k_2 + n) \right), \quad (107)$$

onde  $\Psi_{k_2}$  é a quantidade (total) de energia produzida da iteração 0 para a iteração  $k_2$  e  $\Psi_D$  representa a soma total das demandas internas das três usinas. Observe que  $\sigma$  é uma variável de folga usada para incorporar a tolerância de  $\pm 20\%$  além da geração do contrato de  $\Psi$ ; o *RTO* deve minimizar esse valor, garantindo que ele esteja restrito a  $[-0, 2\Psi, 0, 2\Psi]$ .  $D^j(k_2)$  representa as demandas internas de MG  $j$  no instante de amostragem  $k_2$ : essas curvas são conhecidas, uma vez que a operação do processamento da cana é planejada antecipadamente por uma camada de supervisão de processo separada. Pelo mesmo motivo,  $\Psi_D$  também é conhecido e dado por

$$\Psi_D = \sum_{k_2=0}^{N_{RTO}} \left( D^A(k_2) + D^B(k_2) + D^C(k_2) \right). \quad (108)$$

Note-se que tal função de custo tem um horizonte contrativo de  $(N_{RTO} - k_2)$  passos, que diminui ao passar do tempo. Isso significa que a camada EMS está preocupada com o horizonte de um mês completo (iniciando a operação com um horizonte de amostras de 60 e finalizando com um horizonte de amostra de 1), sendo reinicializada para amostras de 60 quando o mês terminar.

**Observação 2.** Antes de apresentar a formulação completa do *RTO*, deve-se observar que é possível optar por compensar o consumo de energia da rede a cada 12 horas. Neste trabalho



esse desenvolvimento é negligenciado, uma vez que a compra de energia da rede ocorre em raras ocasiões. No entanto, considerando que a compra total de energia de cada MG é  $U_{CT}^j = \sum_{h=k-12}^k U_{comprada}^j(h)$ , as outras duas microrredes  $m$  e  $i$  devem introduzir o equivalente a  $1,1U_{CT}^j$  na rede nas doze horas seguintes para compensação (os 10% representam uma taxa de transmissão cobrada pelo distribuidor). Os MGCCs de nível inferior também devem garantir que a compra da rede seja feita apenas em casos emergenciais ( $U_{comprado}^j$  deve, portanto, ser incluído na função de custo dos MGCCs e ser minimizado).

A segunda parte da função custo do RTO que visa garantir o compartilhamento adequado de recursos da biomassa é dado por

$$J_{RTO}^{Bio} = \sum_{n=1}^{N_{RTO}-k_2} \|R^{Bio}(k_2 + n)\|_{Q_{Tp}}^2 + \|\text{col}\{Bm_{usada}^j(k_2 + n)\}\|_{Q_{usada}}^2, \quad (109)$$

onde  $Q_{Tp}$  e  $Q_{usada}$  são matrizes de ponderação que consideram o custo de transporte (de  $j$  a  $m$  e queima em  $m$ ) versus o custo da queima local, em reais, dadas por <sup>8</sup>

$$Q_{Tp} = \text{diag}\{ (2 \cdot 15 + 25\lambda_B) \quad (3 \cdot 15 + 27\lambda_C) \quad \dots \\ (2 \cdot 15 + 17\lambda_A) \quad (15 + 27\lambda_C) \quad \dots \\ (3 \cdot 15 + 17\lambda_A) \quad (15 + 25\lambda_B) \}, \quad (110)$$

$$Q_{Used} = \text{diag}\{ 17\lambda_A \quad 25\lambda_B \quad 27\lambda_C \}, \quad (111)$$

onde os fatores  $\lambda_A$ ,  $\lambda_B$  e  $\lambda_C$  se relacionam com o estado atual de cada uma das microrredes. Isso significa que se um determinado MG  $j$  estiver em boas condições tem-se  $\lambda_j = 1$ , enquanto que se a eficiência de um MG diminuir, seu custo de manutenção associado poderá aumentar, assim como  $\lambda_j$ . Esses fatores são informados a partir do nível inferior para o nível superior (MORATO, Marcelo M. *et al.*, 2019).

Esta parte do objetivo do RTO,  $J_{RTO}^{Bio}$ , trabalha para refletir se é mais lucrativo queimar biomassa localmente ou transportá-la para outra MG. Na Eq. (110), a primeira entrada dessa matriz diagonal  $Q_{Tp}$  é responsável pelo peso de  $R_{A \text{ para } B}^{Bio}(k_2 + n)$  e leva em consideração o custo do deslocamento de "A" a "B" (2 horas de viagem, R\$ 30,00) mais o custo O&M de biomassa queimada em "B" (R\$ 25,00). De maneira equivalente, na Eq. (111), a primeira entrada pesa  $Bm_{usado}^A(k_2 + n)$ , levando em consideração o custo da queima de biomassa em MG "A", ou seja, R\$ 17,00.

<sup>8</sup> Observe que cada  $Bm_{usada}^j$  da coleção considerada é calculado de acordo com a Eq. (105), usando  $\rho^j = 1$ , conforme discutido anteriormente.

Finalmente, o problema de otimização quadrático  $QP$  resolvido pelo RTO é dado por

$$\min_{\sigma, R(k), R^{Bio}(k), R^l(k)} \frac{J_{RTO}^{\Psi}}{\max\{J_{RTO}^{\Psi}\}} + \frac{J_{RTO}^{Bio}}{\max\{J_{RTO}^{Bio}\}} \quad (112a)$$

s.a.

$$x_3^j(k_2 + n) = x_3^j(k_2 + n - 1) + P_{PV}^j(k_2 + n) + P_{BT}^j(k_2 + n) \quad (112b)$$

$$Bm_{total}^j(k_2 + n) = Bm_{in}^j(k_2 + n) + \sigma_{tk} R_{i \rightarrow j}^{Bio}(k_2 + n - 1) + \sigma_{tk} R_{m \rightarrow j}^{Bio}(k_2 + n - 1) \quad (112c)$$

$$P_{PV}^j(k_2 + n) = \xi_{PV}^j \hat{I}^j(k_2 + n) \quad (112d)$$

$$\min\{\Omega_{BT}^j\} \leq P_{BT}^j(k_2 + n) \leq \xi_{BT}^j Bm_{total}^j(k_2 + n) \quad (112e)$$

$$0 \leq R_{j \rightarrow i}^{Bio}(k_2 + n) \leq d_j(k)(1 - d_{i \rightarrow j}(k)) \overline{R^{Bio}} \quad (112f)$$

$$0 \leq R_{j \rightarrow m}^{Bio}(k_2 + n) \leq d_j(k)(1 - d_{m \rightarrow j}(k)) \overline{R^{Bio}} \quad (112g)$$

$$\sum_{j=A}^C x_3^j(N_{RTO}) = \Psi + \Psi_D + \sum_{n=1}^{N_{RTO}-k_2} R_A^l(k_2 + n) + \sum_{n=1}^{N_{RTO}-k_2} R_B^l(k_2 + n) + \sum_{n=1}^{N_{RTO}-k_2} R_C^l(k_2 + n) \quad (112h)$$

$$-0.2\Psi \leq \sigma \leq 0.2\Psi. \quad (112i)$$

com  $n = 1 \dots N_{RTO} - k_2$ .

O  $QP$  acima possui  $2 + 3 \times 6$  restrições<sup>9</sup>. Note-se que as restrições (112h)e(112i) são fixas, enquanto que as restrições (112b) a (112g) se repetem para  $j = A, B$  e  $C$ .

As seguintes considerações devem ser feitas com respeito ao problema de otimização  $QP$ :

- (i) As restrições de igualdade (112b) afirmam que o estado de geração de energia  $x_3^j$  é um integrador da energia produzida pelos painéis fotovoltaicos e pelas turbinas, que é, basicamente, a extensão de previsão derivada da Eq. (100). Note-se que a energia da bateria não é considerada nesse nível superior, pois é usada para compensar flutuações rápidas de energia no nível inferior.
- (ii) Cada restrição de igualdade (112c) corresponde à receita de biomassa para cada MG  $j$ , que é a extensão da Eq. (102) para o domínio discreto  $k_2$ .
- (iii) As restrições de igualdade (112d) estão relacionadas à energia fornecida pelo painel fotovoltaico  $PV$  referente à previsão de irradiação solar  $\hat{I}^j$  (conforme descrito no capítulo 5). Observe que essa igualdade é a extensão da previsão derivada da Eq. (101).

<sup>9</sup> As restrições do problema de otimização RTO aumentam linearmente com o número de microrredes. Isso significa que o método proposto pode ser estendido trivialmente para um caso com muitas microrredes. A desvantagem seria a necessidade de implementação de um MGCC para cada MG e o aumento do número de restrições da camada RTO que crescem linearmente, resultando em  $2 + 6n_{microrredes}$ , onde  $n_{microrredes}$  significa o número de microrredes.

- (iv) Cada restrição de desigualdade (112e) corresponde à energia máxima e mínima produzida pelas turbinas a vapor, dentro do horizonte de previsão. Note-se que o valor mínimo corresponde ao ponto operacional físico mínimo dessas unidades (fornecido dentro de cada conjunto  $\Omega_{BT}^j$ ) e que o valor máximo corresponde à queima de toda a receita de biomassa disponível (está implícito que esse valor é menor do que o máximo  $\max\{\Omega_{BT}^j\}$ ). Mais uma vez, note-se que  $\xi_{BT}^j$  é o ganho da transformação de biomassa em energia.
- (v) As restrições (112f) e (112g) são responsáveis por garantir que o transporte de biomassa de uma usina para outra seja limitado pelo número máximo de caminhões disponíveis  $\overline{R^{Bio}}$ . Observe que variáveis inteiras são usadas porque só é possível carregar caminhões cheios. A conversão de caminhões em biomassa é dada por  $\sigma_{tk} \frac{\text{Mg}}{\text{trucks}}$ . O valor do limite máximo ( $\overline{R^{Bio}}$ ), de fato, depende da mão de obra disponível para carregar e transportar a biomassa em caminhões. Quando o RTO é executado à meia-noite, a mão-de-obra disponível é menor (8 : 00 a 12 : 00), considerada como 15 caminhões, enquanto ao executar-se ao meio-dia, a mão de obra disponível é maior (12 : 00 a 17 : 00 período de trabalho), considerado 20 caminhões<sup>10</sup>.
- (vi) As restrições (112f) e (112g) usam as variáveis binárias predefinidas  $d_j(k)$ ,  $d_{i \rightarrow j}(k)$  e  $d_{m \rightarrow j}(k)$  que são usados para indicar, respectivamente: a) se  $j$  estiver configurado para enviar biomassa para outro lugar, b) se  $i$  estiver configurado para enviar biomassa para  $j$  e c) se  $m$  estiver configurado para enviar biomassa para  $j$ . Essas variáveis são incluídas para garantir que uma MG não envie biomassa para outra MG que esteja, por sua vez, enviando alguma quantidade de biomassa para outra MG, evitando assim uma eventual situação de “recirculação de biomassa”. Essa decisão é realizada fora do problema de otimização do RTO e com base em uma proposição lógica: se nível de biomassa em MG  $j$  é igual ou superior a um valor mínimo, então  $j$  é definido como fornecedor de biomassa (ou seja,  $d_j(k) = 1$ ), caso contrário, esta MG é definida apenas como receptora de biomassa (isto é,  $d_j(k) = 0$ ).
- (vii) A restrição de igualdade (112h) garante que a geração de energia (soma dos estados  $x_3^A$ ,  $x_3^B$  e  $x_3^C$ ) corresponda à soma da referência do contrato ( $\Psi$ ) com a soma das necessidades da demanda interna ( $\Psi_D$ ), ao final do mês.
- (viii) Finalmente, a restrição de desigualdade (112i) garante que a variável de folga  $\sigma$  permaneça dentro de seu conjunto delimitado, garantindo que a meta de produção de energia contratada seja  $\Psi \pm 0,2\Psi$  (incluindo a tolerância).

**Observação 3.** O problema de otimização acima mistura números inteiros com variáveis contínuas e reais. Esse tipo de formulação é geralmente chamada de problema de compromisso

<sup>10</sup> Observa-se que, com quinze caminhões cheios, pode-se transportar 525 toneladas (Mg) de biomassa e 700 Mg com vinte.

(especialmente realizado em conjunto com despacho econômico), como visto em referências relacionadas (UMMELS et al., 2007; FARSADI et al., 2015). Tal problema é solucionável com algoritmos genéticos (SHOULTS et al., 1980) ou com solvers específicos (KAZARLIS et al., 1996). De qualquer forma, neste documento, o problema é dividido em dois procedimentos de otimização separados, de forma que possa ser resolvido com solvers padrão de programação quadrática encontrando uma solução sub-ótima. O primeiro procedimento resolve as desigualdades dedicadas ao problema de compartilhamento de biomassa (112c), (112f) e (112g) e minimiza  $J_{RTO}^{Bio}$  com respeito a  $R^{Bio}(k)$ ; enquanto que o segundo procedimento resolve os problemas relacionados à energia, considerando o restante das restrições. O problema é resolvido em duas partes, como visto na Figura 47, que mostra a implementação proposta do RTO esquematizada em duas partes.

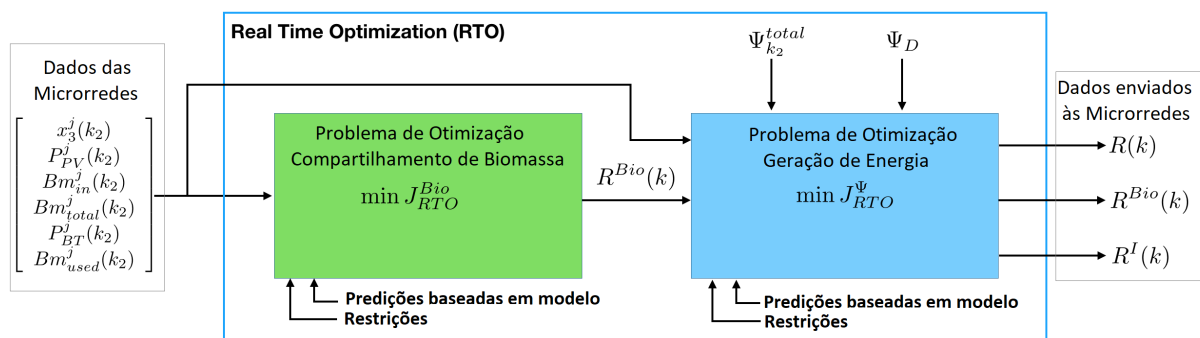


Figura 47 – Esquema do RTO

## 6.5 CAMADA INFERIOR: MPC MGCCS

Esta seção descreve os MGCCs (camada inferior), cujo objetivo é garantir o rastreamento (*tracking*) do setpoint dado pela camada superior e, ao mesmo tempo, mitigar os efeitos de perturbações locais. Há na literatura várias abordagens para enfrentar o problema do rastreamento de referência (BLANCHINI; MIANI, 2000; LIMON et al., 2008; LIMON, Daniel et al., 2012; ALAMO, Teodoro et al., 2014). Neste trabalho utiliza-se a abordagem do chamado MPC para *Tracking* de (LIMON et al., 2008) que faz uso das chamadas referências artificiais para que o problema de otimização do MPC tenha garantida a sua factibilidade.

O MPC para *tracking* é projetado para minimizar a norma quadrática (distância) entre o ponto de operação atual e a referência repassada pelo RTO, de forma que, caso a referência seja um ponto inalcançável para o modelo do MPC, o controlador determinará um ponto de operação o mais próximo daquele repassado pelo RTO. Desta forma, os MPC locais sempre encontrarão soluções admissíveis para o sistema, garantindo a factibilidade da solução. Embora o problema abordado neste trabalho não apresente necessariamente problemas de estabilidade (porque sua dinâmica é baseada em nós integradores), essa abordagem (usando referências artificiais) é escolhida devido à sua versatilidade e garantias de factibilidade. No entanto, é

importante ressaltar que essa estratégia pode ser usada para qualquer MG que exija garantias de convergência assintótica.

Portanto, para cada MG  $j$  a camada superior RTO define quatro referências:  $R_j(k)$ ,  $R_{j \rightarrow i}^{Bio}(k)$ ,  $R_{j \rightarrow m}^{Bio}(k)$  e  $R_j^I(k)$ . As MGCCs devem garantir que, dentro das próximas 12 horas (período de amostragem do RTO), essas referências sejam rastreadas.

Sendo assim, é importante ressaltar que dois horizontes de previsão devem ser definidos com o intuito de garantir o rastreamento de referência: *i*) um horizonte fixo e de tamanho  $N_{MGCC} = T_{RTO}$ ; e *ii*) um horizonte contrativo de  $N_{MGCC}^{k, k_2} = (k_2 + 1)T_{RTO} - k$ .

A estratégia de controle para seguimento das referências repassadas pelo RTO é explicada a seguir:

- (i) No final de cada período  $T_{RTO}$  (da iteração  $k$ , dado como  $N_{MGCC}^{k, k_2}$  passos à frente), a quantidade produzida de energia por MG  $j$  deve ser igual a  $R_j(k + N_{MGCC}^{k, k_2}) + R_j^I(k + N_{MGCC}^{k, k_2})$  mais as demandas internas da MG, resultando em

$$J_{MGCC}^1 = \|x_3^j(k + N_{MGCC}^{k, k_2}) - x_s^j\|_P^2, \quad (113)$$

$$R_{x_s}^j = R_j(k + N_{MGCC}^{k, k_2}) \quad (114)$$

$$+ R_j^I(k + N_{MGCC}^{k, k_2})$$

$$+ \sum_{n=k}^{k+N_{MGCC}^{k, k_2}} D^j(n),$$

$$J_{MGCC}^2 = \|x_s^j - R_{x_s}^j - \rho^j\|_T^2, \quad (115)$$

sendo  $x_s^j$  a referência artificial, ponderada por  $T$ , que compõe a parcela que minimiza a distância entre ela e o valor da produção total de energia  $R_{x_s} + \rho^j$  (sendo  $\rho^j$  uma folga variável), enquanto  $x_3^j$  é ponderado por  $P$  para estar o mais próximo possível de  $x_s^j$ .

- (ii) Deseja-se produzir o máximo de energia possível (considerando o limite superior da produção de energia como a referência artificial  $x_s^j$ ), resultando em

$$J_{MGCC}^3 = \sum_{n=k}^{k+N_{MGCC}} \|x_3^j(n) - x_s^j\|_Q, \quad (116)$$

sendo  $Q$  uma matriz de ponderação.

- (iii) As matrizes de ponderação usadas são:

$$P = 0.5 \mathbb{I}_{\text{size}(x_3^j)}, \quad Q = 0.5P, \quad (117)$$

$$T = 0.06 N_{MGCC}^{k, k_2} P. \quad (118)$$

- (iv) As restrições para as referências artificiais são estabelecidas por

$$0 \leq x_s^j \leq \frac{1}{15} \Psi, \quad (119)$$

o que significa que, dentro de  $T_{RTO}$ , uma MG só pode produzir, no máximo, um décimo quinto da meta mensal total de produção, o que é uma escolha coerente. Produzir energia em excesso pode ser indesejável, uma vez que a meta total do contrato de energia de  $\Psi$  não deve ser sobreposta em mais de 20 %; a geração excessiva pode resultar em multas devido a taxas de transmissão de energia. Além disso, a variável de folga definida na referência é definida pela tolerância do contrato (mas pode ser alterada de acordo com o supervisor local)

$$-0.2R_{x_s}^j \leq \rho^j \leq 0.2R_{x_s}^j. \quad (120)$$

- (v) Em termos do rastreamento de referência de compartilhamento de biomassa, é possível deduzir que apenas duas restrições são necessárias, sendo elas

$$\sum_{n=k}^{k+N_{MGCC}^{k,k_2}} u_{j \rightarrow i}(n) = - \sum_{n=k-(12-N_{MGCC}^{k,k_2})}^k u_{j \rightarrow i}(n) + \sigma_{tk} R_{j \rightarrow i}(N_{MGCC}^{k,k_2}) \quad (121)$$

$$\sum_{n=k}^{k+N_{MGCC}^{k,k_2}} u_{j \rightarrow m}(n) = - \sum_{n=k-(12-N_{MGCC}^{k,k_2})}^k u_{j \rightarrow m}(n) + \sigma_{tk} R_{j \rightarrow m}(N_{MGCC}^{k,k_2}) \quad (122)$$

sendo cada  $u_{j \rightarrow i}(k)$  e  $u_{j \rightarrow m}(k)$  tomados como uma variável inteira múltipla de  $\sigma_{tk}$ , com limites dados por

$$0 \leq u_{j \rightarrow i}(k) \leq \sigma_{tk} \overline{R^{Bio}} \quad (123)$$

$$0 \leq u_{j \rightarrow m}(k) \leq \sigma_{tk} \overline{R^{Bio}}. \quad (124)$$

- (vi) Considera-se que as microrredes só devem trocar biomassa (através de caminhões) se a MG que recebe biomassa tiver seus estoques de biomassa ( $x_2^j(k)$ ) abaixo de um valor predefinido  $\underline{x}_2^j$ , enquanto que as microrredes que enviam biomassa devem ter seus estoques acima de um valor mínimo. Esta é uma definição coerente, uma vez que a queima local deve ser priorizada na maioria dos casos<sup>11</sup>

- (vii) Finalmente, considerando as restrições na entrada de controle, definem-se as restrições

$$\min\{\Omega_{BT}^j\} \leq u_{BT}^j \leq \max\{\Omega_{BT}^j\}, \quad (125)$$

$$\min\{\Omega_{Bat}^j\} \leq u_{Bat}^j \leq \max\{\Omega_{Bat}^j\}. \quad (126)$$

<sup>11</sup> Se uma MG ainda tiver muita biomassa para queimar, não faz sentido transportá-la continuamente para outro lugar e deixar de utilizá-la localmente. Portanto, ele só deve transportar quantidades de biomassa se "souber" que outra MG não possui biomassa para queimar.

Todo o desenvolvimento acima leva ao problema quadrático completo que define os MPCs locais que funcionam como MGCCs, sendo estes definidos por

$$\min_{u^j, u_{out}^j} = \sum_{h=1}^3 J_{MGCC}^h \quad (127)$$

s. t.  $\left\{ \begin{array}{l} \text{Restrições dadas por} \\ \text{Eqs. (119), (120), (121), (122),} \\ \text{(123), (124), (125) e (126)} \end{array} \right.$

A Figura 48 mostra um esquema de como cada MGCC funciona, dada a informação/orientação que vem da camada superior RTO.

Sendo assim, tendo detalhado o funcionamento tanto do RTO quanto dos MGCCs, apresenta-se o algoritmo 1 que descreve como sua implementação é feita.

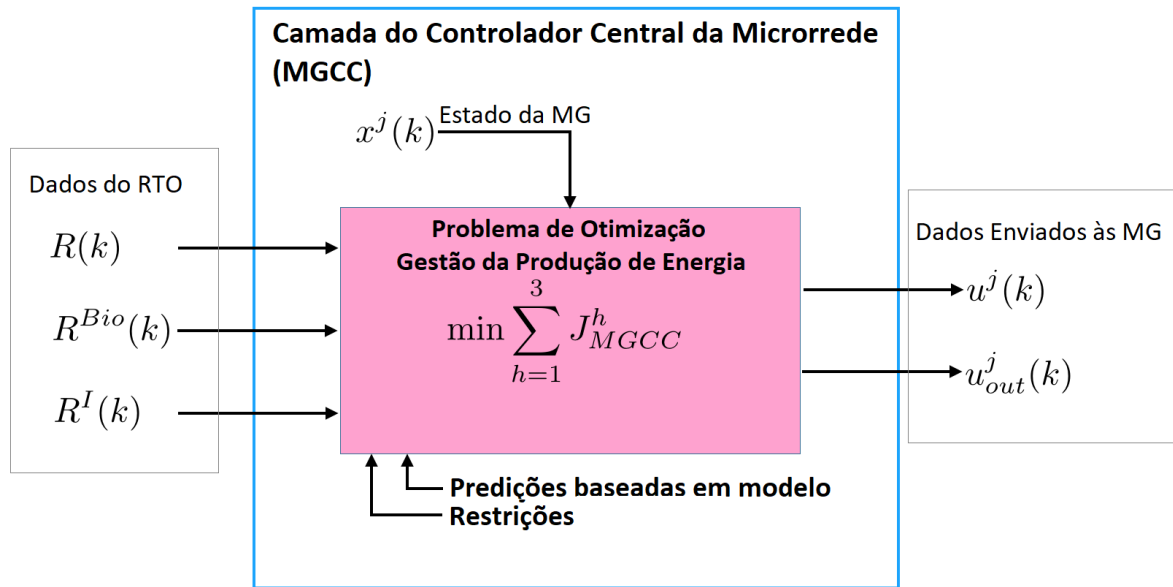


Figura 48 – Representação Esquemática das MGCCs

**Algoritmo 1.** Implementação do EMS (RTO + MGCCs)

1. Faça  $k = 0, k_2 = 0$ .
2. Calcule o vetor de entradas do RTO, de acordo com as Eqs. (100) - (105), levando em conta dados passados (conhecidos) das microrredes;
3. Minimize  $J_{RTO}^{Bio}$  com respeito a  $R^{Bio}$  sujeito a (112c), (112f) e (112g);
4. Tome a primeira entrada como  $R^{Bio}(k)$ ;
5. Minimize  $J_{RTO}^{\Psi}$  com respeito a  $\{\sigma, R, R^I\}$  sujeito a (112b), (112d), (112e), (112g), (112h) e (112i);

6. Tome a primeira entrada como  $\{\sigma, R(k), R^l(k)\}$ ;
7. Calcule, para cada MG:
  - a) O estado de realimentação  $x^3(k)$ ;
  - b) Minimize  $\sum_{h=1}^3 J_{MGCC}^h$  com respeito a  $\{u^j, u_{out}^j\}$  sujeito a (119)-(126).
  - c) Tome a primeira entrada como  $\{u^j(k), u_{out}^j(k)\}$  e aplique ela como a ação de controle.

## 6.6 CASO DE ESTUDO

Esta seção mostra exemplos de simulação numérica para demonstrar como o EMS hierárquico proposto trabalha para coordenar o caso investigado das três microrredes. Para tal, dois cenários diferentes são apresentados para avaliar diferentes situações da casos reais. Um ilustra a operação normal (em que cada MG funciona normalmente), enquanto o outro ilustra um cenário em que eles são obrigados a cooperar em termos de transporte de biomassa para alcançar a meta de energia ao final do mês.

Neste trabalho usaram-se os seguintes *softwares*: *Matlab* (MATHWORKS, 2017), *Yalmip* toolbox (LOFBERG, 2004) e *SDPT 3 solver* (TOH *et al.*, 1999). O *Matlab* (junto com o *Yalmip*) é usado para programar o Algoritmo 1, bem como a simulação numérica do modelo de processo, conforme indicado na Eq. (92). Os procedimentos de otimização (comandos de minimização no Algoritmo 1) são resolvidos pelo *solver SDPT 3*. Todas as simulações apresentadas na sequência derivam de iterações de otimização delimitadas e factíveis.

As perturbações  $w$  foram criadas a partir de dados reais da entrada de biomassa (bagaço e palhiço) para uma planta real de processamento de cana-de-açúcar, assim como os dados reais de irradiação solar para diferentes locais do estado de São Paulo.

### 6.6.1 Cenário 1: Operação Normal

O primeiro cenário de simulação é o de operação normal do EMS proposto. Nesse caso, nenhum tipo de condição anormal é considerada, como chuva concentrada em apenas uma das microrredes, ou como o período final de colheita.

A Figura 49 mostra as curvas de irradiação solar usadas (e as estimativas  $\hat{I}^j$ ) para as três microrredes <sup>12</sup>. Este é um desempenho típico do sol nos meses de colheita em no estado de São Paulo. A Figura 50 mostra a entrada da biomassa. Nesse cenário, MG “B” apresenta um ligeiro aumento médio da biomassa disponível, com respeito à Tabela 13.

Os resultados alcançados com o EMS utilizando as perturbações mostradas nas Figuras 49 e 50 são:

<sup>12</sup> As curvas pontilhadas representam gráficos sobrepostos de previsões de irradiação, realizadas a cada hora. Observe que em uma determinada hora  $k$ , as previsões disponíveis são apenas para as próximas 24 horas.



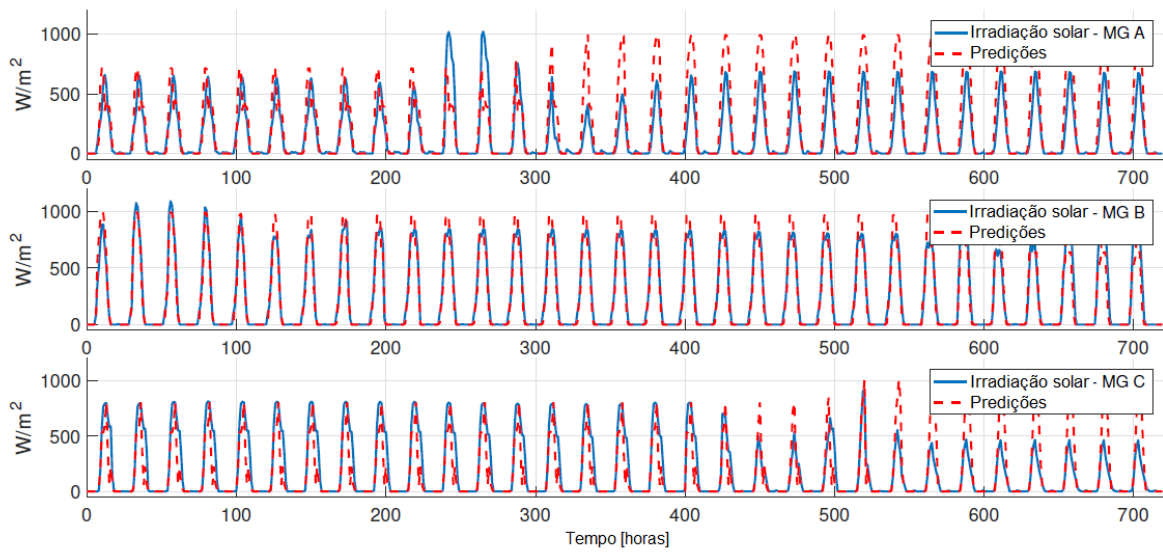


Figura 49 – Cenário 1: Irradiação Solar




Figura 50 – Cenário 1: Entrada de Biomassa

- (i) A Figura 51 mostra a produção combinada de energia das três microrredes, que, no final do mês, atende à meta do contrato  $\Psi$  (somada às demandas internas totais). Note-se que a produção de energia, a cada dia, engloba a energia a ser vendida e a energia para atender às demandas internas (linha azul clara). Por outro lado, as MGCCs garantem o seguimento das referências repassadas pelo RTO apesar de distúrbios e erros de previsão.
- (ii) Nesse cenário, não há biomassa trocada entre as microrredes. Como o vetor  $R^{Bio}(k)$  foi definido como 0 pelo RTO, ele não é mostrado.
- (iii) A Figura 52 mostra como os MGCCs usam os bancos de baterias disponíveis a fim de

equilibrar eventuais indisponibilidades das fontes renováveis.

- (iv) Finalmente, a Figura 53 mostra que os MGCCs também garantem que os estoques de biomassa permaneçam dentro de seus valores mínimos e máximos permitidos.




Figura 51 – Cenário 1: Produção de Energia




Figura 52 – Cenário 1: Estado de Carga das Baterias




Figura 53 – Cenário 1: Nível do Estoque de Biomassa

### 6.6.2 Cenário 2: Fim de colheita

O segundo cenário de simulação é o de uma situação de final de colheita, podendo resultar na necessidade de troca de biomassa entre as microrredes. Neste cenário, as curvas solares são as mesmas utilizadas no Cenário anterior (Figura 49). Entretanto, devido ao cenário de fim de safra os gráficos da entrada de biomassa nas microrredes são diferentes do que os do caso dito “normal”. Motivados por testar o desempenho da proposta em uma situação crítica, optou-se por simular uma interrupção da colheita na MG “B” no primeiro trimestre da simulação, enquanto as outras duas MGs possuem “excesso” de biomassa, especialmente a MG “A”, como mostra a Figura 54.

Os resultados alcançados com o EMS para o segundo cenário são:

- (i) A Figura 55 mostra a produção combinada de energia das três microrredes. Mais uma vez, assim como no primeiro cenário, a meta do contrato de final de mês é atingida. Além disso, as demandas elétricas internas também são alcançadas.
- (ii) As MGCCs seguem utilizando os bancos de baterias disponíveis para compensar a variabilidade da irradiação solar (Figura 56). Note-se que, neste cenário, as baterias não são tão utilizadas quando no primeiro.
- (iii) O gerenciamento da biomassa e a cooperação das três microrredes são representadas na Figura 57. Esta figura mostra os pontos de operação (*setpoints*) definidos pelo RTO ( $R^{Bio}(k)$ ) e a ação das MGCCs (pulsos). Os caminhões são despachados no momento do estabelecimento das referências. É possível verificar que o excesso de biomassa nas microrredes “A” e “C” compensa a falta de biomassa em “B”. Uma vez que os estoques de biomassa de “B” atingem o valor mínimo, o RTO determina que as outras microrredes




Figura 54 – Cenário 2: Entrada de Biomassa

distribuem seus recursos para que a operação de “B” possa ser mantida. As referências de compartilhamento de biomassa definidos pelo RTO são sinais do tipo “degrau”, enquanto que o número real de caminhões enviados de cada MG aparece como um sinal de impulso, demonstrando que, uma vez que os MGCCs recebem a “ordem” de compartilhamento de recursos eles enviam, de uma só vez, o número total de caminhões para transportar a quantidade necessária de biomassa.

- (iv) Finalmente, a Figura 58 mostra como o compartilhamento de recursos atua para garantir que os estoques de biomassa fiquem dentro de seus limites mínimos e máximos.

É possível verificar, com a ajuda desses dois cenários de simulação, que a proposta de duas camadas (RTO/MGCCs) EMS é realmente capaz de gerenciar efetivamente várias microrredes. Este esquema pode ser usado para outros casos semelhantes de coordenação de MGs.

## 6.7 COMENTÁRIOS FINAIS DO CAPÍTULO

Neste capítulo apresentou-se um EMS para o problema de geração de energia distribuída na indústria brasileira de cana-de-açúcar. Conforme mostrado nas simulações baseadas em dados reais, o esquema de duas camadas proposto é capaz de coordenar adequadamente várias microrredes e gerenciar seus recursos para maximizar os objetivos de desempenho de geração de energia.

Os resultados alcançados parecem oferecer uma forma eficiente e suficientemente simples para ser implementada na coordenação de microrredes. Deve-se observar que, para projetar




Figura 55 – Cenário 2: Produção de Energia




Figura 56 – Cenário 2: Estado de Carga da Bateria

o sistema de controle proposto, é necessário apenas: 1) ter o modelo matemático da planta suficientemente acurado (basicamente integradores e ganhos de conversão de energia); 2) medir os estados dos sistemas (estoques e banco de baterias); 3) resolver dois problemas de otimização quadrática em períodos de amostragem relativamente grandes, facilmente realizados em computadores modernos e, até mesmo, em *PLCs*.




Figura 57 – Cenário 2: Gestão da Biomassa




Figura 58 – Cenário 2: Estoque de Biomassa

Em termos de viabilidade de implementação e escalabilidade, a técnica proposta pode ser aplicada na prática com facilidade, mesmo no caso de várias microrredes.

Com relação à sua implementação, algumas considerações são importantes:

- A camada superior RTO pode ser desenvolvida em uma estrutura *on-line*, alimentada com informações (e estados) de produção de energia de cada microrrede.

- Geralmente, os EMS nas microrredes (indústria da cana-de-açúcar) são feitos em PLCs, sendo que a camada dos MGCCs pode ser facilmente incorporada.
- O método proposto pode ser facilmente estendido ao caso de várias microrredes; a complexidade (número de restrições) do procedimento de otimização para o RTO cresce linearmente com o número de microrredes.
- Note-se que os sensores considerados são os normalmente utilizados na operação tradicional, como medições de estoques e baterias. Ou seja, não são necessários sensores dedicados (normalmente com custo elevado) para a implementação do método proposto.

A principal contribuição deste capítulo reside na aplicação prática da abordagem hierárquica RTO + MPC para um problema real no contexto da indústria de cana-de-açúcar brasileira, que, de acordo com o conhecimento do autor, é inédito.

## 7 CONTROLADOR PREDITIVO ECONÔMICO DE UMA CAMADA

Como relatado no capítulo introdutório desta tese, a tarefa de controle nas indústrias de processos é normalmente executada por meio de uma estrutura hierárquica de controle, sendo tipicamente a primeira camada um planejador econômico que determina os parâmetros gerais da planta. Na camada seguinte, composta por um RTO, calculam-se os objetivos (*setpoints*) de produção, isto é, os pontos de operação que o sistema deve alcançar, minimizando um determinado critério econômico levando em conta as informações que recebe da camada de planejamento. Em seguida, os *setpoints* calculados pelo RTO são enviados para o nível de controle do MPC, que calcula as ações de controle necessárias para levar o sistema às referências dadas pelo RTO.

Como já foi dito em capítulos anteriores, um dos problemas da abordagem hierárquica é que a comunicação entre as camadas RTO e MPC pode ser inconsistente, principalmente devido ao fato de que o RTO, normalmente, é baseado em um modelo estático não linear complexo da planta, enquanto que o MPC leva em conta um modelo dinâmico simplificado. Por outro lado, dada a complexidade dos problemas de otimização que a camada de RTO resolve, é comum que o seu tempo de amostragem seja maior que o do MPC. Uma das implicações dessa abordagem é a possibilidade de que um determinado estado estacionário fornecido pelo RTO seja um ponto inatível (inalcançável) para o MPC frente a eventuais mudanças significativas do problema de otimização, como por exemplo no conjunto de restrições ou proveniente da diferença entre o modelo do RTO e do MPC, assim como os erros de modelagem entre a planta real e os modelos utilizados.

Para enfrentar esse problema, o trabalho de Muske (1997) sugere o uso de uma camada intermediária entre o RTO e o MPC chamada *Steady-State Target Optimizer (Steady State Target Optimizer (SSTO))*, que, dada uma referência fornecida pelo RTO, calcula um ponto estacionário viável para ser passado ao MPC, minimizando (normalmente) uma função de custo quadrático que penalize o erro em relação ao ponto de ajuste fornecido pelo RTO.

Um dos controladores MPC que fazem frente ao problema de inconsistências de modelo e mudanças de ponto de operação do sistema é o chamado *MPC for Tracking (MPC para Tracking (MPCT))* (LIMON *et al.*, 2008), que usa modelos dinâmicos de controle. O MPCT é um controlador preditivo que, mesmo para alterações na função de custo do problema, oferece garantia de estabilidade e integra a camada SSTO em sua formulação. Dado um ponto de ajuste calculado pela camada RTO superior, o MPCT encontra uma referência viável para o controlador que seja o mais adequado (por exemplo, o mais próximo desse ponto de ajuste), respeitando as restrições do sistema.

Outra maneira de abordar as dificuldades do controle hierárquico é considerar a chamada formulação econômica do MPC (EMPC)(AMRIT, 2011) (ANGELI *et al.*, 2012) (RAWLINGS, J. B. *et al.*, 2012a), na qual utiliza-se a própria função custo do RTO na formulação do EMPC, resolvendo o problema todo em uma camada. Esta abordagem utiliza a função do RTO como



custo de etapa do EMPC oferecendo a vantagem de calcular não apenas um ponto estacionário ótimo, mas a trajetória ótima, o que melhora a otimalidade econômica do controlador. Na formulação do EMPC, os autores provam que, se o sistema é dissipativo em relação à função de custo, existe uma função de Lyapunov associada ao sistema sem ter a necessidade de que a função de custo seja positiva definida, o que torna possível garantir que o sistema em malha fechada seja assintoticamente estável (ANGELI *et al.*, 2012).

Apesar da vantagem que o EMPC oferece ao agregar as funcionalidades do RTO e do MPC, a estabilidade e a factibilidade recursiva podem ser perdidas no caso de alterações na função econômica (LIMON, D. *et al.*, 2013; FERRAMOSCA *et al.*, 2014).

Por outro lado, para contornar eventuais problemas de complexidade do problema de otimização, os autores Souza *et al.* (2010) utilizam o gradiente da função objetivo econômico incluindo-o na função custo do controlador a fim de obter uma estratégia com baixo custo computacional. Uma formulação aprimorada dessa abordagem é apresentada por Alamo *et al.* (2012), onde os autores utilizam uma estratégia de MPC sub-ótimo garantindo a factibilidade recursiva e a convergência para o alvo ideal (em termos econômicos) com um custo computacional reduzido.

Baseado nas contribuições de Souza *et al.* (2010) e Alamo *et al.* (2012), D. Limon *et al.* (2013) propõem uma estratégia de MPC de uma camada aprimorada, adicionando uma aproximação de segunda ordem da função custo do RTO ao custo do MPC. Desta forma, o problema de otimização é transformado em um problema convexo, exigindo apenas uma avaliação do gradiente da função de custo econômico em cada período de amostragem. Essa abordagem tem a vantagem de garantir a factibilidade recursiva e a convergência para atingir o estado estacionário economicamente ótimo do sistema ainda sob mudanças da função econômica.

Entretanto, apesar das estratégias de controle apresentadas anteriormente permitirem otimizar o desempenho em caso de alteração das funções de custo econômico, as incompatibilidades entre a planta real e o modelo de predição podem fazer com que a planta controlada não convirja ao ponto de operação ideal da planta real. Uma abordagem relevante que surgiu no contexto da Otimização em Tempo Real é uma metodologia chamada *Modifier Adaptation* (MA), que aborda o problema do erro de modelagem fazendo correções no problema de otimização. Isso é feito incluindo termos modificadores nas restrições e na função de custo (ou no modelo), fazendo com que as saídas do modelo e do processo real converjam (MARCHETTI, A. *et al.*, 2009).

Uma das contribuições desta tese é agregar ao trabalho de D. Limon *et al.* (2013) uma abordagem adaptativa que permita aprimorar o modelo do sistema a fim de minimizar a discrepância entre planta e modelo e, dessa forma, oferecer um controlador com *offset-free*, ou seja, que o controlador convirja ao ponto ótimo da planta *real*.

Nos trabalhos de Vaccari e Pannocchia (2017, 2018), aborda-se o problema de erro de modelo propondo um controlador EMPC com *offset-free* utilizando a metodologia de adaptação

via modificadores. Nessa mesma direção, Hernández e Engell (2019) apresentaram uma variação desse trabalho, utilizando medidas do transiente para calcular os modificadores. O controlador proposto nesta tese vai na mesma direção de projetar um controlador *offset-free*, porém baseado no controlador MPC para *Tracking* de uma camada, estendendo o trabalho de D. Limon *et al.* (2013) e aproveitando as suas vantagens: garantias de estabilidade, convergência e factibilidade recursiva, mesmo utilizando um modelo linear do processo (o que facilita muito a resolução do problema de otimização) e sem perder a factibilidade em casos de mudanças na função de custo econômica.

A seguir serão apresentados os fundamentos do controlador MPC para *Tracking*, assim como a metodologia de adaptação via modificadores para, posteriormente, apresentar o controlador MPC Econômico de uma Camada proposto nesta tese.

### 7.1 MPC PARA TRACKING (MPCT)

Um dos objetivos do chamado MPC para *Tracking* é de, dado um *setpoint* calculado pela camada superior de RTO, encontrar um ponto factível para o controlador MPC que seja o mais próximo desse *setpoint* respeitando as restrições do sistema.

Seja o sistema dado por

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) \\y(k) &= Cx(k) + Du(k)\end{aligned}\tag{128}$$

sendo  $x \in \mathbb{R}^n$  o vetor estado do sistema,  $u \in \mathbb{R}^m$  a entrada e  $y \in \mathbb{R}^p$  a saída. Assume-se que o par  $(A, B)$  seja estabilizável e que o sistema esteja sujeito às restrições de estado e de entrada dadas por

$$(x(k), u(k)) \in \mathbb{Z} = \{z \in \mathbb{R}^{n+m} : A_z z \leq b_z\}, \quad \forall k \geq 0\tag{129}$$

sendo  $A_z$  e  $b_z$  as matrizes que definem as restrições e  $\mathbb{Z}$  um conjunto não nulo e compacto contendo a origem em seu interior.

Para garantir a factibilidade do MPC para *Tracking*, Limon *et al.* (2008) utilizam o conceito de referencia artificial, de forma que o problema de otimização oferece como solução, além da entrada  $u$  a ser aplicada ao sistema, o ponto de equilíbrio admissível que minimize um determinado custo de *offset*, como por exemplo o ponto mais próximo ao *setpoint* do RTO. Desta forma, mesmo que o *setpoint* repassado pela RTO não seja um ponto de equilíbrio (ponto admissível) do sistema, a solução do problema de otimização sempre oferece uma ação de controle e um ponto admissível a ser seguido, motivo pelo qual, desde que o ponto inicial seja um ponto de equilíbrio do sistema, o MPC para *Tracking* sempre oferecerá uma solução admissível para o sistema, isto é, garante-se a factibilidade do controlador.

Como o objetivo do controlador é levar o sistema ao ponto estacionário que minimize determinado critério, faz-se necessário estabelecer a representação do sistema em regime

permanente em função do ponto estacionário  $(x_S, u_S) = z_S \in \mathbb{Z}$ , de forma que

$$\begin{aligned} x_S &= Ax_S + Bu_S \\ y &= Cx_S + Du_S \end{aligned} \quad (130)$$

que pode ser escrito como

$$\begin{aligned} 0_{n,1} &= (A - I_n)x_S + Bu_S \\ y &= Cx_S + Du_S \end{aligned} \quad (131)$$

ou, equivalentemente, por

$$\begin{bmatrix} A - I_n & B \\ C & D \end{bmatrix} \begin{bmatrix} x_S \\ u_S \end{bmatrix} = \begin{bmatrix} 0_{n,1} \\ y \end{bmatrix}. \quad (132)$$

Ou seja, o par  $(x_S, u_S)$  só será um ponto de equilíbrio se

$$\begin{bmatrix} (A - I_n) & B \end{bmatrix} \begin{bmatrix} x_S \\ u_S \end{bmatrix} = 0_{n,1}. \quad (133)$$

Isto implica em que o par  $(x_S, u_S)$  deve estar contido no espaço nulo da matriz  $[(A - I_n) \ B]$ .

Portanto, a função custo do MPC para *Tracking* é definida como

$$V_N(\hat{x}, x^{sp}; u, x_S, u_S) = \sum_{i=0}^{N-1} \|\hat{x}(i) - x_S\|_Q^2 + \|u(i) - u_S\|_R^2 + Vo(x_S - x^{sp}) \quad (134)$$

com  $x^{sp}$  sendo o *setpoint* repassado pelo RTO e  $Q \in \mathbb{R}^{n \times n}$  e  $R \in \mathbb{R}^{m \times m}$  matrizes de ponderação definidas positivas.

A última parcela da função custo  $Vo(x_S - x^{sp})$  é a chamada função custo de *offset* (ou custo de *Tracking*), que penaliza a desviação entre a referência artificial e a referência do RTO<sup>1</sup>, de forma que seja única a solução do problema de otimização

$$\min_{x_S} Vo(x_S - x^{sp}) = \min \|x_S - x^{sp}\|_T^2. \quad (135)$$

sendo  $T \in \mathbb{R}^{n \times n}$  uma matriz de ponderação definida positiva. Para facilitar o entendimento do controlador MPCT e com o objetivo de simplificar o caso de estudo a ser utilizado nas próximas seções onde será feita a integração do controlador com as estratégias de correção do erro de modelagem, optou-se por apresentar o controlador MPCT utilizando restrição terminal de igualdade, que é um caso particular da restrição com região terminal. Entretanto, é possível utilizar uma restrição terminal de desigualdade (região terminal) no controlador MPCT, como é detalhado na seção 7.1.1.

<sup>1</sup>  $Vo$  deve ser uma função convexa, positiva definida, tal que  $Vo(0) = 0$

Sendo assim, o problema de otimização a ser resolvido pelo MPC para *Tracking* é

$$\min_{u, x_S, u_S} V(N)(\hat{x}, x^{SP}; u, x_S, u_S)$$

$$\text{s.a. } \hat{x}(0) = x(k), \quad (136a)$$

$$\hat{x}(j+1) = A\hat{x}(j) + Bu(j), \quad (136b)$$

$$(\hat{x}(j), u(j)) \in \mathbb{Z}, \quad j = 0, \dots, N-1, \quad (136c)$$

$$x_S = Ax_S + Bu_S \quad (136d)$$

$$\hat{x}(N) = x_S \quad (136e)$$

sendo que Limon *et al.* (2008) demonstram que o sistema controlado pelo MPC para *Tracking* proposto leva o sistema de qualquer ponto inicial factível a qualquer *setpoint* admissível repassado pelo RTO de forma assintótica garantindo, portanto, a estabilidade. Ainda, se o *setpoint* repassado pelo RTO for inalcançável (infactível), o controlador garante que levará o sistema de forma factível ao ponto de equilíbrio  $x^{SP}$  que minimize a função de custo de *offset*  $V_0$ , isto é, se  $x^{SP}$  não for um ponto de equilíbrio possível do modelo, será calculado um  $x_S$  que o seja para o problema de otimização 136.

### 7.1.1 Controlador MPCT - Cálculo da Região Terminal

Como dito anteriormente, o controlador MPCT utiliza uma restrição terminal como um dos elementos garantidores da estabilidade do sistema, cuja necessidade foi verificada na seção 2.3. Entretanto, a restrição terminal pode ser tanto uma região terminal (restrição de desigualdade) ou um ponto específico (restrição de igualdade). Naturalmente, uma restrição de igualdade é muito mais “dura” do que aceitar uma região em que  $\hat{x}(N)$  esteja contido. Portanto, a utilização da região terminal no problema de otimização tem a vantagem de proporcionar um aumento considerável do domínio de atração do sistema em malha fechada e pode ser utilizada sempre e quando seja viável o cálculo de uma região terminal como sendo um invariante positivo do sistema.

Portanto, o problema de otimização do controlador MPCT pode ser escrito como

$$\min_{u, x_S, u_S} V(N)(\hat{x}, x^{SP}; u, x_S, u_S)$$

$$\text{s.a. } x_0 = 0, \quad (137a)$$

$$\hat{x}(j+1) = A\hat{x}(j) + Bu(j), \quad (137b)$$

$$(\hat{x}(j), u(j)) \in \mathbb{Z}, \quad j = 0, \dots, N-1, \quad (137c)$$

$$x_S = Ax_S + Bu_S \quad (137d)$$

$$(\hat{x}(N), x_S, u_S) \in \mathcal{X}_f^W \quad (137e)$$

com  $\mathcal{X}_f^W \subseteq \mathbb{R}^{2n_x+n_u}$  sendo um invariante positivo para o sistema estendido  $(\hat{x}, x_S, u_S)$ .

O calculo da região terminal  $\mathcal{X}_f^W$  leva em conta a dinâmica de malha fechada do sistema (128). Portanto, definindo a lei de controle como sendo

$$u = K(\hat{x} - x_S) + u_S \quad (138)$$

sendo que se os autovalores da matriz  $A+BK$  estiverem todos dentro do círculo unitário, então o sistema evoluirá ao ponto estacionário  $(x_S, u_S)$ .

Considere o seguinte sistema em malha fechada

$$w(k+1) = \begin{bmatrix} \hat{x} \\ x_S \\ u_S \end{bmatrix} (k+1) = \begin{bmatrix} A+BK & -BK & B \\ 0 & I_n & 0 \\ 0 & 0 & I_m \end{bmatrix} = A_W w(k) \quad (139)$$

cujo vetor de estados aumentado é  $w = (\hat{x}, x_S, u_S)$ .

Seja o politopo convexo  $W_\lambda$  para  $\lambda \in [0, 1]$  definido por

$$W_\lambda = \{w = (\hat{x}, x_S, u_S) : (\hat{x}, K(\hat{x} - x_S) + u_S) \in \mathbb{Z}, (x_S, u_S) \in \lambda \mathbb{Z}\}. \quad (140)$$

O conjunto  $\mathcal{X}_f^W$  será um conjunto invariante positivo para ser utilizado como restrição terminal no MPC para *Tracking* se  $A_W w \in \mathcal{X}_f^W$  para todo  $w \in \mathcal{X}_f^W$  e  $\mathcal{X}_f^W \subseteq W_{\lambda=1}$ .

O conjunto invariante máximo para o *Tracking* será definido por  $\mathcal{O}_\infty^W = \{w : A_W^i w \in W_1, \forall i \geq 0\}$ . Devido aos autovalores unitários de  $A_W$  este conjunto não é finito (GILBERT, E. G.; TAN, 1991). Entretanto, é possível determinar o conjunto

$$\mathcal{O}_{\infty, \lambda}^W = \{w : A_W^i w \in W_\lambda, \forall i \geq 0\} \quad (141)$$

que é um poliedro convexo limitado para qualquer valor de  $\lambda \in (0, 1)$ . Dado que  $\lambda \mathcal{O}_\infty^W \subset \mathcal{O}_{\infty, \lambda}^W \subset \mathcal{O}_\infty^W$  e  $\lambda$  pode ser escolhido arbitrariamente perto de 1 o conjunto invariante obtido pode ser utilizado como uma boa aproximação do máximo conjunto invariante  $\mathcal{O}_\infty^W$ .

## 7.2 ALGORITMOS DE IDENTIFICAÇÃO DE PARÂMETROS

Dentre as metodologias encontradas na literatura para enfrentar os erros de modelagem em sistemas RTO está a técnica de adaptação de modificadores, cujos métodos podem ser divididos em três grupos (B. CHACHUAT; D. BONVIN, 2009): *i*) adaptação modelo-paramétrica, que utiliza medidas do processo para aprimorar o modelo e, com o modelo atualizado, resolver o problema de otimização; *ii*) adaptação com modificadores, que também utiliza medidas do processo, porém consiste em corrigir a função custo e as restrições do problema de otimização acrescentando-lhes os chamados modificadores; *iii*) adaptação direta das entradas, em que as entradas são modificadas através de um laço de realimentação, sendo que este método utiliza um controlador calculado de maneira *offline* e que, portanto, não requer a utilização de métodos de otimização *online*.

Este trabalho explora o método de adaptação através de modificadores (*Modifier Adaptation - Adaptação via Modificadores* (Modifyer Adaptation (MA)), suas vantagens, aplicações

e variações. A metodologia MA baseia-se no chamado método das duas etapas que consiste na solução de dois problemas matemáticos para corrigir o erro de modelagem: numa primeira etapa, utilizam-se as medidas da saída do processo para calcular os parâmetros desconhecidos do modelo e, em uma segunda etapa, calcula-se a ação de controle resolvendo-se o problema de otimização com os parâmetros encontrados de forma iterativa até que o algoritmo convirja. Esta metodologia foi adaptada por P. D. Roberts (1979) incluindo o cálculo dos gradientes da função objetivo com respeito às variáveis de decisão no cálculo dos modificadores. A inclusão de tais gradientes possibilita que o método alcance as chamadas condições necessárias de otimalidade (CNO). Esse método foi chamado de (*Integrated System Optimization and Parameter Estimation*) (ISOPE) (*Integrated System Optimization and Parameter Estimation*) e é conhecido como o ponto de partida da metodologia que utiliza a modificação via adaptadores.

### 7.2.1 Método das Duas Etapas (Two-Step Approach)

Seja o modelo estático do processo dado por

$$f(x, u, \alpha) = 0 \quad (142a)$$

$$g(x, u, \alpha) \leq 0 \quad (142b)$$

$$y = h(x, u, \alpha) \quad (142c)$$

sendo  $f$  e  $g$  funções possivelmente não lineares que representam o modelo estático do sistema e as restrições de desigualdade do sistema, respectivamente. Ainda,  $y$  representa a função que mapeia as saídas do sistema,  $x$  os estados do sistema,  $u$  o vetor das variáveis manipuladas, e  $\alpha$  o vetor contendo os parâmetros do modelo.

Considerando que a função custo do RTO seja dada por uma determinada função  $\ell$ , o problema de otimização a ser resolvido pelo RTO poderia ser escrito por

$$P_o \triangleq \min_u \ell(x, u, \alpha) \quad (143a)$$

$$s.a. \quad f(x, u, \alpha) = 0 \quad (143b)$$

$$g(x, u, \alpha) \leq 0 \quad (143c)$$

$$y = h(x, u, \alpha). \quad (143d)$$

Buscando estimar o parâmetro desconhecido  $\alpha$ , aplica-se o valor encontrado da variável manipulada  $u$  tanto ao processo real quanto ao modelo e busca-se o valor de  $\alpha$  que leve ambas as saídas a convergirem. Isto é feito através da solução de um problema de otimização que minimiza um determinado índice de comparação entre as saídas. O problema de otimização

$$P_e \triangleq \min_{\alpha} R(y_p, y) \quad (144a)$$

$$s.a. \quad f(x, u, \alpha) = 0 \quad (144b)$$

$$g(x, u, \alpha) \leq 0 \quad (144c)$$

$$y = h(x, u, \alpha) \quad (144d)$$

normalmente utiliza como índice de comparação uma função  $R$  dada por

$$R(y_p, y) = \|y_p - y\|^2. \quad (145)$$

sendo que o método requer a medição dos valores da saída do processo  $y_p$  e do modelo  $y$  em um ponto estacionário.

Levando em conta que, de maneira geral, os modelos matemáticos não representam com fidelidade o comportamento do processo real, a solução do problema de estimação de parâmetros  $P_e$  apresenta o valor de  $\alpha$  como uma função da variável manipulada  $u$  do problema de otimização  $P_o$ . Portanto, para encontrar o valor de  $\alpha$  que, para determinado valor de  $u$ , leve a saída do modelo o mais próximo do valor da saída do processo real, ambos os problemas de otimização devem ser resolvidos de forma iterativa até se encontrar o ponto de operação ótimo para o processo real. Este processo iterativo é conhecido como a abordagem de dois passos, sendo estes:

**Passo 1:** Aplica-se o valor da entrada atual  $u$  ao sistema real, aguarda-se que o sistema atinja o ponto de operação estacionário correspondente e se obtém o valor da saída  $y_p$ . Resolve-se o problema de estimação de parâmetros  $P_e$  para encontrar o valor de  $\alpha$  que minimize o critério de comparação  $R$ .

**Paso 2:** Com o valor do parâmetro  $\alpha$  obtido no passo 1 resolve-se o problema de otimização  $P_o$  que minimiza o critério de desempenho  $\ell$ .

Repetem-se os dois passos iterativamente até que não haja melhora nos índices de desempenho dos problemas de otimização.

Entretanto, foi demonstrado (ROBERTS; WILLIAMS, 1980 apud DURBECK, 1965) que apenas este procedimento não garante convergência ao ponto estacionário ótimo da planta na presença de erros de modelagem. Os autores demonstram que a condição de otimalidade é alcançada se os gradientes do processo real coincidirem com os do modelo utilizado. Esse conceito foi utilizado por P. D. Roberts (1979) para desenvolver o chamado método ISOPE (*Integrated System Optimization and Parameter Estimation*), apresentado a seguir.

### 7.2.2 ISOPE

O método ISOPE é uma versão modificada do método de duas etapas que insere o cálculo dos gradientes da função custo alcançando, com isso, as condições de otimalidade que garantem que o sistema convirja ao ótimo real do processo. Inicialmente, o método redefine algumas variáveis com o intuito de isolar os dois problemas de otimização envolvidos  $P_o$  e  $P_e$ , substituindo-se  $\alpha$  por  $\sigma$  no problema de otimização  $P_o$  e  $u$  por  $v$  no problema de estimação  $P_e$ , de forma que

$$v = u \quad (146a)$$

$$\sigma = \alpha. \quad (146b)$$

O Problema de otimização, já com as variáveis substituídas, é dado por

$$\min_u \ell(x, u, \sigma) \quad (147a)$$

$$s.a. \quad f(x, u, \sigma) = 0 \quad (147b)$$

$$g(x, u, \sigma) \leq 0 \quad (147c)$$

$$y = h(x, u, \sigma) \quad (147d)$$

sendo que substituindo a restrição de igualdade para eliminar a dependência de  $x$  em  $\ell$  e ignorando-se as restrições de desigualdade,  $\ell(x, u, \sigma)$  transforma-se em  $\Phi(u, \sigma)$  e o problema de otimização anterior resulta em

$$\min_u \Phi(u, \sigma). \quad (148)$$

Da mesma forma, substituindo  $u$  por  $v$  no problema de estimação de parâmetros, obtém-se

$$\min_\alpha R(y_p, y) \quad (149a)$$

$$s.a. \quad f(x, v, \alpha) = 0 \quad (149b)$$

$$g(x, v, \alpha) = 0 \quad (149c)$$

$$y = h(x, v, \alpha) \quad (149d)$$

que, de maneira similar ao problema anterior, este pode ser escrito por

$$\min_\alpha \Psi(v, \alpha). \quad (150)$$

O problema de estimação de parâmetros pode ser considerado equivalente a encontrar o valor de  $\alpha$  que satisfaz

$$\frac{\partial}{\partial \alpha} \Psi(v, \alpha) = 0 \quad (151)$$

sempre e quando assumamos que o ótimo do problema de estimação ocorra em uma região em que não estejam ativas as restrições, ou seja, em uma região factível.

A solução do problema completo, incluindo os dois subproblemas, pode ser encontrada resolvendo o seguinte problema de otimização

$$\min_\alpha \Phi(u, \sigma) \quad (152a)$$

$$s.a. \quad v = u \quad (152b)$$

$$\sigma = \alpha \quad (152c)$$

$$\frac{\partial}{\partial \alpha} \Psi(v, \alpha) = 0 \quad (152d)$$

que equivale a encontrar o ponto estacionário do Lagrangeano<sup>2</sup>:

$$L(u, v, \sigma, \alpha, \lambda_u, \lambda_\alpha, \lambda_\Psi) = \Phi(u, \sigma) + \lambda_u'[v - u] + \lambda_\alpha'[\sigma - \alpha] + \lambda_\Psi' \frac{\partial}{\partial \alpha} \Psi(v, \alpha) \quad (153)$$

<sup>2</sup> A solução de um problema de otimização através do método de Lagrange consiste em converter o problema de otimização com restrições de igualdade em um problema irrestrito incorporando as restrições à função objetivo.



sendo  $\lambda_U$ ,  $\lambda_\alpha$  e  $\lambda_\Psi$  os multiplicadores de Lagrange.

Levando em conta que o método de estimação de parâmetros exige que o sistema esteja em um ponto de operação estacionário, a condição necessária para a aplicação do método de Lagrange é cumprida, já que se tem

$$\nabla L(u, v, \sigma, \alpha, \lambda_U, \lambda_\alpha, \lambda_\Psi) = 0 \quad (154)$$

ou, equivalentemente, nas derivadas parciais

$$\frac{\partial L}{\partial u} = \frac{\partial}{\partial u} \Phi(u, \sigma) - \lambda_U = 0 \quad (155a)$$

$$\frac{\partial L}{\partial v} = \frac{\partial^2}{\partial v \partial \alpha} \Psi(v, \alpha) \lambda_\Psi + \lambda_U = 0 \quad (155b)$$

$$\frac{\partial L}{\partial \sigma} = \frac{\partial}{\partial \sigma} \Phi(u, \sigma) + \lambda_\alpha = 0 \quad (155c)$$

$$\frac{\partial L}{\partial \alpha} = \frac{\partial^2}{\partial \alpha \partial \alpha} \Psi(v, \alpha) \lambda_\Psi - \lambda_\alpha = 0 \quad (155d)$$

$$\frac{\partial L}{\partial \lambda_U} = v - u = 0 \quad (155e)$$

$$\frac{\partial L}{\partial \lambda_\alpha} = \sigma - \alpha = 0 \quad (155f)$$

$$\frac{\partial L}{\partial \lambda_\Psi} = \frac{\partial}{\partial \alpha} \Psi(v, \alpha) = 0. \quad (155g)$$

Resolver a equação (155a) equivale a encontrar o mínimo da função  $\Phi$  através da solução do problema de otimização

$$\min_u \quad \Phi(u, \sigma) - \lambda'_U u \quad (156)$$

que reescrevendo-o juntamente com as restrições de igualdade (modelo) e de desigualdade resulta no problema de otimização completo

$$\min_u \quad C(x, u, \sigma) - \lambda'_U u \quad (157a)$$

$$s.a. \quad f(x, u, \sigma) = 0 \quad (157b)$$

$$g(x, u, \sigma) \leq 0 \quad (157c)$$

$$y = h(x, u, \sigma) \quad (157d)$$

com  $\lambda_U$  e  $\sigma$  conhecidos. Para determinar o valor de  $\lambda_U$  resolve-se o sistema de equações (155b-155d), que resulta em

$$\lambda_U = \frac{\partial^2}{\partial \alpha \partial \alpha} \Psi(v, \alpha) \left[ \frac{\partial^2}{\partial v \partial \alpha} \Psi(v, \alpha) \right]^{-1} \frac{\partial}{\partial \sigma} \Phi(u, \sigma). \quad (158)$$

No caso especial em que houver o mesmo número de medições do que de parâmetros a estimar, o problema de estimação de parâmetros pode-se resolver utilizando-se a mesma entrada  $v$  tanto para a saída do processo  $y_p(v)$  quanto do modelo  $y(v, \alpha)$ , de forma que a equação (158) pode ser escrita como

$$\lambda_U = \left[ \left[ \frac{\partial y}{\partial v} \right]' - \left[ \frac{\partial y_p}{\partial v} \right]' \right] \left[ \frac{\partial y}{\partial \alpha} \right] \frac{\partial}{\partial \sigma} \Phi(u, \sigma). \quad (159)$$

Com o intuito de aprimorar a estabilidade do método, o autor sugere a substituição da equação (152b) pelo filtro de primeira ordem dado por

$$v(k) = v(k-1) + K_f[u(k) - v(k-1)]. \quad (160)$$

sendo  $K_f$  uma matriz diagonal com os ganhos do filtro,  $0 \leq k(i) \leq 1$ . O Algoritmo 2 descreve uma maneira de implementar o método ISOPE.

**Algoritmo 2.** ISOPE (P. D. ROBERTS, 1979)

1. Uma vez que o processo tenha atingido um estado estacionário, resolve-se o problema de estimação de parâmetros (149a-149d) utilizando a leitura da saída da planta real.
2. Estando ainda no mesmo ponto estacionário, obtém-se\* o gradiente da saída da planta real com respeito à entrada  $u$  e calcula-se o modificador  $\lambda_U(k)$  segundo 159. OBS: Para o cálculo de  $\lambda_U(k)$  também deve-se calcular o gradiente do modelo da planta.
3. Calcula-se o valor de  $u(k)$  resolvendo o problema de otimização modificado (157a) utilizando os valores de  $\lambda_U(k)$  calculados no passo anterior.
4. Aplica-se o filtro de primeira ordem (160) aos valores de  $u(k)$  para calcular a entrada  $v(k)$  a ser implementada ao processo.
5. Verifica-se se o valor da função objetivo (157a) converge ou se cumpre algum outro critério de convergência. Caso o sistema não haja convergido aguarda-se o processo atingir novamente o estado estacionário, incrementa-se  $k$  e retorna-se ao 1 repetindo os passos até que o critério de convergência tenha sido atingido.

\*Pode-se utilizar o método de diferenças finitas para calcular o gradiente da planta, se o processo assim o permitir.

O método ISOPE é uma adaptação do método de duas etapas que, através da inclusão do modificador  $\lambda_U$ , garante que o ponto ótimo de operação do processo seja alcançado. O método original pode ser implementado com o Algoritmo 2 fazendo  $\lambda_U = 0$ .

Uma das dificuldades dos métodos baseados na estimação de gradientes do processo em regime permanente é que nem sempre é possível, ou é difícil de fazê-lo. Uma alternativa é

utilizar métodos que permitam estimar os valores dos gradientes da planta em linha, ou seja, durante o transitório. Desta maneira, o tempo que o processo leva para alcançar um regime estacionário não é impedimento para realizar uma nova estimação e aprimorar o modelo, uma vez que durante um ponto estacionário e outro pode haver mudanças nas perturbações e restrições do processo fazendo com que o ponto estacionário calculado anteriormente deixe de ser ótimo. Alguns destes métodos podem ser vistos nos trabalhos de Alejandro G. Marchetti *et al.* (2016) e Rodriguez-Blanco *et al.* (2017).

### 7.2.3 Metodologia de Adaptação via Modificadores

A metodologia de adaptação do modificador (MA) utilizada originalmente por J. F. Forbes *et al.* (1994), apresenta algumas variantes na literatura, tais como W. Gao e S. Engell (2005), P. Tatjeski (2002), B. Chachuat e D. Bonvin (2009) e A. Marchetti *et al.* (2009). Em geral, o método busca fazer com que as condições necessárias de otimalidade (CNO), também conhecidas como condições KKT (Karush-Kuhn-Tucker), do processo real e do modelo de predição sejam alcançadas através da utilização de modificadores na função custo e nas restrições do problema de otimização, permitindo compensar erros de modelagem paramétricos e estruturais.

Seja o seguinte problema de otimização resolvido pelo RTO

$$\min_{x_s, u_s} J(x_s, u_s, p) \quad (161a)$$

$$\text{s.t. } f(x_s, u_s) = 0 \quad (161b)$$

$$h(x_s, u_s) \leq 0, \quad (161c)$$

em que  $x_s$  e  $u_s$  representam o estado e ações de controle que definem o estado estacionário ótimo da planta;  $J$  é a função custo que depende do parâmetro do RTO  $p$  (por exemplo, o preço das matérias-primas ou os custos de produção); (161b) representa o modelo estático da planta e (161c) determina as restrições operacionais da planta.

Seguindo a estrutura hierárquica de controle, o RTO fornece ao MPC um ponto operacional ótimo  $(x_s, u_s)$ , dado por (161). No entanto, se o critério econômico mudar, devido a variações do parâmetro  $p$ , o estado estacionário economicamente ótimo admissível onde o controlador levaria o sistema pode mudar, e a factibilidade do controlador pode ser perdida. Para enfrentar esse problema, Limon *et al.* (2008) propuseram um controlador que lida com essa questão e, além disso, integra o RTO na camada de controle do MPC, assunto tratado a seguir.

Assumindo que a restrição (161c) não esteja ativa em um determinado ponto de operação  $(x_0, u_0)$  e que as funções  $J(x_s, u_s, p)$  e  $h(x_s, u_s)$  são diferenciáveis em  $(x_0, u_0)$ , haverá um único vetor de multiplicadores de Lagrange  $\lambda \in \mathbb{R}^{nh}$  cujas condições KKT são

cumpridas no ponto  $(x_0, u_0)$ , sendo estas

$$f(x_s, u_s) = 0 \quad (162a)$$

$$h(x_s, u_s) \leq 0 \quad (162b)$$

$$\lambda_f f(x_s, u_s) = 0 \quad (162c)$$

$$\lambda_h h(x_s, u_s) = 0 \quad (162d)$$

$$\lambda_f \geq 0 \quad (162e)$$

$$\lambda_h \geq 0 \quad (162f)$$

$$\nabla L(x_s, u_s, p, \lambda) = 0, \quad (162g)$$

com  $L(x_s, u_s, p, \lambda) = J(x_s, u_s, p) + \lambda_f f(x_s, u_s) + \lambda_h h(x_s, u_s)$  sendo o Lagrangeano do problema de otimização (161).

De acordo com A. Marchetti *et al.* (2009), uma outra possibilidade de implementar a metodologia de adaptação de modificadores é modificando diretamente o modelo, ao invés da função custo. Considerando que o sistema está sujeito a restrições na entrada e no estado, a restrição (161c) pode ser definida como

$$\bar{u} \leq u \leq \underline{u} \quad (163a)$$

$$\bar{x} \leq x \leq \underline{x}, \quad (163b)$$

sendo  $(\bar{x}, \bar{u})$  os limites máximos e  $(\underline{x}, \underline{u})$  os limites mínimos, de forma que (161) pode ser reescrita acrescida dos modificadores, resultando no problema de otimização aumentado:

$$\min_u J(x, u, p) \quad (164a)$$

s.t.

$$\hat{x} = f(\hat{x}, u) + \lambda'_{u,k}(u - u(k)) + \lambda'_{x,k}(\hat{x} - x(k)) + \epsilon(k) \quad (164b)$$

$$\bar{u} \leq u \leq \underline{u} \quad (164c)$$

$$\bar{x} \leq \hat{x} + \epsilon(k) \leq \underline{x} \quad (164d)$$

com os modificadores dados por

$$\lambda_{u,k} = \left. \frac{\partial f_p(x, u)}{\partial u} \right|_{u(k)} - \left. \frac{\partial f(x, u)}{\partial u} \right|_{u(k)} \quad (165a)$$

$$\lambda_{x,k} = \left. \frac{\partial f_p(x, u)}{\partial x} \right|_{x(k)} - \left. \frac{\partial f(x, u)}{\partial x} \right|_{x(k)} \quad (165b)$$

$$\epsilon(k) = f_p(x(k), u(k)) - f(x(k), u(k)), \quad (165c)$$

sendo que  $f_p$  se refere ao modelo da planta real. A solução do problema (164) resulta no cálculo do seguinte ponto de operação ótimo  $(x(k+1), u(k+1))$ .

Para garantir a viabilidade do problema de otimização, tais modificadores podem ser filtrados com filtros de primeira ordem

$$\hat{\lambda}(k) = [I - \beta]\lambda_{k-1} + \beta\lambda(k) \quad (166)$$

com  $\beta \in (0, 1]$ .

#### 7.2.4 MPC para Tracking de uma Camada (One-Layer MPCT)

Como foi dito na seção 2.2, há varias propostas para melhorar as dificuldades encontradas na troca de informações dinâmicas e econômicas entre as camadas de uma estrutura de controle hierárquico. Porém, muitos dos sistemas D-RTO e MPC de duas camadas propostos são caracterizados por uma falta de tratamento teórico rigoroso, incluindo as restrições (VACCARI; PANNOCCHIA, 2018). Por outro lado, a abordagem chamada de formulação econômica do MPC (EMPC) apresenta, com todo o rigor teórico, uma formulação que inclui os aspectos econômicos do RTO no MPC e oferece garantia de estabilidade em um controlador de uma camada. Porém, como já foi ressaltado, dada a complexidade que as funções custo com critério econômico possuem, tal controlador está sujeito a resolver problemas de otimização complexos que podem influenciar no tempo de resolução do problema de otimização. Além disso, a estabilidade e a factibilidade recursiva podem ser perdidas em caso de mudanças na função de custo econômica (LIMON, D. *et al.*, 2013).

Da mesma forma que o EMPC inclui aspectos econômicos do RTO na sua formulação, D. Limon *et al.* (2013) propõem um controlador que agrega critérios econômicos na sua formulação utilizando uma aproximação de segunda ordem da função de custo do RTO através de uma abordagem adaptativa baseada em gradientes que será apresentada a seguir.

#### 7.2.5 Estratégia baseada em Gradiente para o One-Layer MPCT

Supondo que o vetor de saída da planta  $y_S$  defina exclusivamente um ponto de equilíbrio da planta, é possível representar o ponto de equilíbrio em função da saída da planta com  $x_S = g_x(y_S)$  e  $u_S = g_u(y_S)$ . A substituição dessas funções no problema de otimização do RTO (161) pode ser reescrita como

$$\min_{y_S} f_{eco}(y_S, \rho) \quad (167a)$$

$$\text{s.t. } h_q(y_S) \leq 0, \quad q \in \mathbb{I}_{1:n_h}, \quad (167b)$$

onde  $n_h$  é o número de restrições,  $f_{eco}$  e  $h_q$  estão intimamente relacionados a  $J(x_S, u_S, \rho)$ ,  $f(x_S, u_S)$  e  $h(x_S, u_S)$ , mas representados em função de  $y_S$ . O conjunto viável desse problema de otimização é indicado como  $\mathcal{Y}_t$ . As seguintes considerações são feitas

**Hipótese 4.**  $f_{eco}$  e  $h_q$  são funções convexas.

**Hipótese 5.** A solução do problema de otimização do RTO é única

Considere que um certo ponto de equilíbrio viável do RTO  $z$  seja escolhido para calcular uma aproximação da função  $f_{eco}(y, \rho)$ , D. Limon *et al.* (2013) sugerem o uso de uma aproximação de Taylor de segunda ordem para representar as funções  $f_{eco}$  e  $h_q(y)$ , isto é

$$f_{eco}(y, \rho) \leq f_{eco}(z, \rho) + \nabla_y f_{eco}(z, \rho)^T (y - z) + \frac{\rho_f}{2} \|y - z\|^2 \quad (168)$$

e

$$h_q(y) \leq h_q(z) + \nabla_y h_q(z)^T (y - z) + \frac{\pi_q}{2} \|y - z\|^2, \quad q \in \mathbb{I}_{1:n_h} \quad (169)$$

para todos  $y \in \mathcal{Y}_t$  e  $z \in \mathcal{Y}_t$ , com  $\mathcal{Y}_t$  sendo o conjunto factível do problema de otimização.

Portanto, a função custo aproximada para o MPC proposto pode ser definida como

$$\begin{aligned} V_N^a(x, \hat{d}, \rho; u, x_s, u_s) = & \sum_{j=0}^{N-1} \|\hat{x}(j) - x_s\|_Q^2 + \|u(j) - u_s\|_R^2 + \\ & f_{eco}(z, \rho) + \\ & \nabla_y f_{eco}(z, \rho)^T (y - z) + \frac{\rho_f}{2} \|y - z\|^2 \end{aligned} \quad (170)$$

Com o conjunto convexo

$$\mathcal{Y}_t^a(z) = \left\{ y : \begin{aligned} & h_j(z) + \nabla_y h_j(z)^T (y - z) \\ & + \frac{\pi_j}{2} \|y - z\|^2 \leq 0, j \in \mathbb{I}_{1:n_h} \end{aligned} \right\} \quad (171)$$

sendo que  $\mathcal{Y}_t^a(z) \subseteq \mathcal{Y}_t$  para todo  $z \in \mathcal{Y}_t$ .

O MPC tem um modelo de predição dado por

$$\hat{x}(k+1) = f_{mpc}(\hat{x}(k), u(k)) = A\hat{x}(k) + Bu(k) \quad (172a)$$

$$y(k) = C\hat{x}(k), \quad (172b)$$

sendo que  $\hat{x} \in \mathcal{R}^n$  é o vetor de estados do sistema,  $u \in \mathcal{R}^m$  é o vetor de controle e  $y \in \mathcal{R}^p$  o vetor de saídas sujeito às restrições de estados e de entradas.

$$(\hat{x}(k), u(k)) \in \mathcal{Z} = \{z \in \mathbb{R}^{n+m} : A_z z \leq b_z\}, \quad \forall k \geq 0, \quad (173)$$

sendo que o conjunto  $\mathcal{Z}$  é assumido como sendo convexo, fechado e contém a origem no seu interior

Portanto, o problema de otimização a ser resolvido pelo MPC é obtido substituindo a função de custo original e as restrições pelas aproximadas, de modo que  $P(N)^a(\hat{x}, \hat{d}, \rho)$  é

dado por

$$\min_{u, x_S, u_S} V_N^a(\hat{x}, \hat{d}, p; u, x_S, u_S) \quad (174a)$$

$$\text{s.t. } \hat{x}(0) = x(k), \quad (174b)$$

$$\hat{x}(j+1) = A\hat{x}(j) + Bu(j) + \hat{d}, \quad (174c)$$

$$(\hat{x}(j), u(j)) \in Z, \quad j = 0, \dots, N-1, \quad (174d)$$

$$x_S = Ax_S + Bu_S + \hat{d}, \quad (174e)$$

$$y_S = Cx_S + Du_S \quad (174f)$$

$$\hat{x}(N) = x_S \quad (174g)$$

$$y_S \in \mathcal{Y}_t^a(z). \quad (174h)$$

A solução desse problema de otimização fornecerá um ponto viável para o MPC o mais próximo possível da solução RTO. Quaisquer incompatibilidades decorrentes da diferença entre o modelo linear e a planta podem ser levadas em consideração por  $\hat{d}$ . Assim, o problema de otimização original é transformado em um problema convexo, exigindo apenas uma avaliação do gradiente da função de custo econômico em cada período de amostragem. Os autores sugerem usar o melhor ponto de equilíbrio alcançável como um ponto de linearização, ou seja, usar o valor de  $y_S$  calculado no instante anterior. Essa abordagem tem a vantagem de garantir factibilidade recursiva e convergência para alcançar o estado estacionário economicamente ideal do sistema (LIMON, D. *et al.*, 2013).

No entanto, sabe-se que existe uma diferença entre o modelo usado pelos controladores e o processo real da planta. Se o controlador tivesse acesso ao modelo real da planta, a solução seria certamente ótima. Em vez disso, a existência de um erro de modelagem faz com que a solução do problema (174) apresente um erro (*offset*). Esse problema pode ser enfrentado usando modificadores no problema de otimização, estratégia chamada Adaptação via Modificadores.

### 7.2.6 Controlador MPC Econômico de uma Camada

O MPC (174) pode levar em conta quaisquer erros de modelagem entre a planta atual e o modelo utilizado pelo controlador se for possível estimar o parâmetro  $\hat{d}$ . No entanto, esta abordagem requer saber exatamente a natureza das incertezas, a fim de criar um modelo de estimativa de perturbação, o que dificulta a sua aplicação (VACCARI; PANNOCCHIA, 2017). Uma alternativa para esse problema é integrar os modificadores ao modelo de previsão do MPC, permitindo o projeto de um controlador que alcance o ótimo da planta, ou seja, um controlador livre de *offset*.

A principal contribuição deste capítulo é a reformulação do controlador MPC para *Tracking* apresentado na seção 7.2.5 integrando a técnica de adaptação via modificadores (MA). O resultado é o projeto de um controlador MPC de uma camada que herda as boas propriedades

de ambas as abordagens: satisfação das restrições, garantia de estabilidade e convergência ao ponto de operação economicamente ótimo da *planta real* sob qualquer mudança do critério econômico.

Considerando o MPC (174), a correção do erro de modelagem entre o modelo de previsão e a planta real pode ser feita adicionando modificadores ao modelo de predição, sendo que o ponto de operação estacionário real ótimo  $(x_s, u_s)$  pode ser calculado resolvendo o seguinte problema de otimização

$$\min_{u, x_s, u_s} V_N^{ma}(\hat{x}, \hat{d}, p; u, x_s, u_s) \quad (175a)$$

$$s.t. \quad x(0) = x(k), \quad (175b)$$

$$\begin{aligned} \hat{x}(j+1) = A\hat{x}(j) + Bu(j) + \lambda_{u,k}^T(u(j) - u(k)) + \\ \lambda_{x,k}^T(\hat{x}(j) - x(k)) + \epsilon(k), \end{aligned} \quad (175c)$$

$$(\hat{x}(j) + \epsilon(k), u(j)) \in Z, \quad j = 0, \dots, N-1, \quad (175d)$$

$$\begin{aligned} x_s = Ax_s + Bu_s + \lambda_{u,k}^T(u_s - u(k)) + \\ \lambda_{x,k}^T(x_s - x(k)) + \epsilon(k), \end{aligned} \quad (175e)$$

$$(x_s + \epsilon, u_s) \in Z, \quad (175f)$$

$$\hat{x}(N) = x_s \quad (175g)$$

com  $V_N^{ma}(\hat{x}, \hat{d}, p; u, x_s, u_s)$  definida por

$$V_N^{ma} = \sum_{j=0}^{N-1} \|\hat{x}(j) - x_s\|_Q^2 + \|u(j) - u_s\|_R^2 + \quad (176a)$$

$$J(x_s(k-1), u_s(k-1), p) + \quad (176b)$$

$$\nabla_x J(x_s(k-1), u_s(k-1), p)^T (x_s - x_s(k-1)) + \quad (176c)$$

$$\nabla_u J(x_s(k-1), u_s(k-1), p)^T (u_s - u_s(k-1)) + \quad (176d)$$

$$\frac{\rho_x}{2} \|x_s - x_s(k-1)\|^2 + \quad (176e)$$

$$\frac{\rho_u}{2} \|u_s - u_s(k-1)\|^2 \quad (176f)$$

com  $x_s(k-1)$  e  $u_s(k-1)$  sendo o ponto estacionário no instante  $k-1$ . Os modificadores  $\lambda_{u,k}^T$ ,  $\lambda_{x,k}^T$ ,  $\epsilon(k)$  da equação (175c-175e) são dados por

$$\lambda_{u,k}^T = \nabla_u f_p(x(k), u(k)) - \nabla_u f(x(k), u(k)) \quad (177a)$$

$$\lambda_{x,k}^T = \nabla_x f_p(x(k), u(k)) - \nabla_x f(x(k), u(k)) \quad (177b)$$

$$\epsilon(k) = f_p(x(k), u(k)) - f(x(k), u(k)). \quad (177c)$$

Os operadores  $\nabla_u f$  e  $\nabla_x f$  são os Jacobianos com respeito a  $u$  e  $x$ , calculados no ponto de equilíbrio  $(x(k), u(k))$ .



### 7.2.7 Propriedades do Controlador MPC Econômico de uma Camada

O controlador (175) mantém a mesma estrutura de um controlador MPC para *Tracking* (LIMON *et al.*, 2008), herdando suas principais propriedades como: estabilidade, factibilidade e garantia de estabilidade e convergência. Além disso, garante a convergência para o ponto de operação ótimo da *planta real*, mesmo que o controlador tenha um modelo impreciso. Isso devido à compensação feita pela adaptação via modificadores, resultando em um controlador livre de *offset*. As propriedades são detalhadas a seguir:

1. *Factibilidade Recursiva*: pelo fato de que o MPC Econômico de uma Camada utiliza as chamadas variáveis artificiais (variáveis de otimização que representam o melhor ponto de equilíbrio admissível para o modelo MPC, herança da formulação do MPCT (LIMON *et al.*, 2008)), e uma restrição de igualdade terminal relaxada, de tal forma que o estado terminal previsto é forçado a ser qualquer ponto de equilíbrio (não o *setpoint*), o controlador garante a factibilidade recursiva, mesmo no caso de mudanças na função custo econômico  $J$ , o que implica que não é necessário recalculá-lo no caso de uma mudança do objetivo econômico.
2. *Implementação Simplificada*: graças às aproximações (168)-(169), o problema de otimização (175) resulta em um problema de Programação Quadrática.
3. *Estabilidade Assintótica*: é possível demonstrar, seguindo os mesmos argumentos utilizados por D. Limon *et al.* (2013), que o controlador proposto garante a estabilidade assintótica em malha fechada.
4. *Offset-Free*: ao utilizar a estratégia de adaptação via modificadores (MARCHETTI, A. *et al.*, 2009), o controlador proposto elimina o erro de modelagem entre o modelo utilizado para previsão e a planta real, de modo que a solução encontrada pelo controlador sempre coincide com o *ponto de operação ideal da planta real*.

## 7.3 EXEMPLO ILUSTRATIVO

Para ilustrar como o controlador proposto funciona, o chamado processo de quatro tanques (JOHANSSON, 2000) é usado como estudo de caso.

O sistema consiste em quatro tanques, dois superiores e dois inferiores, além de um reservatório localizado sob esses tanques. Os tanques superiores têm escoamento livre através de orifícios para os tanques inferiores, como pode ser visto na Figura 59. A água é succionada do reservatório através de duas bombas centrífugas e, por meio de duas válvulas de três vias, a água é direcionada para cada um dos tanques. As variáveis manipuladas são as vazões das bombas  $q$  e os estados  $h$  são os níveis dos tanques. O sistema tem a saída composta por dois estados  $y = (h_1, h_2)$  e a entrada por  $q = (q_1, q_2)$ . O sistema é detalhado no Anexo B.




Figura 59 – Processo dos quatro tanques.

A função econômica do MPC Econômico de uma Camada utilizada para o exemplo é

$$J = \|y_s - y^{sp}\|^2 \quad (178)$$

de forma que o controlador deve levar o sistema a um determinado setpoint ótimo  $y_{sp}$ .

Para demonstrar a existência do chamado *off-set* decorrente de um erro de modelagem, as Figuras (60) e (61) apresentam o resultado do controlador *One-Layer* MPCT com erro de modelagem, ou seja, o modelo do controlador é um modelo linearizado em um ponto de operação e a planta tem seu comportamento não linear real<sup>3</sup>. Nota-se que o sistema não converge para a referência, permanecendo um *off-set* decorrente da inconsistência entre modelo e planta. Para este controlador foi utilizado um horizonte de previsão  $N = 5$  e ponderações  $Q = I$ ,  $R = 0.01 \times I$ . Neste teste foram utilizadas as seguintes referências:  $y_1^{sp} = (1.5, 1.5)$ ,  $y_2^{sp} = (1.6, 1.4)$ ,  $y_3^{sp} = (1.7, 1.8)$ ,  $y_4^{sp} = (1.0, 1.0)$  e  $y_0 = (h_1^0, h_2^0)$ , sendo  $y_0$  o ponto de partida do sistema.

As Figuras 60 e 61 mostram que o sistema não converge para as referências, permanecendo um *offset* devido à inconsistência entre modelo e planta.

<sup>3</sup> Para mais detalhes da modelagem veja Anexo B




Figura 60 – Saída- Sistema controlado pelo Controlador MPC para Tracking com erro de modelagem: planta não linear real e modelo do controlador linearizado.




Figura 61 – Saída do Sistema e Setpontos ótimos - Sistema controlado pelo Controlador MPC para Tracking com erro de modelagem: planta não linear real e modelo do controlador linearizado.

As Figuras 62 e 63 mostram o resultado do controlador MPC Econômico de uma Camada usando MA (175). Pode ser visto, a partir da figura, que o controlador não apresenta




Figura 62 – Saída- Sistema controlado pelo Controlador MPC Econômico de uma Camada com erro de modelagem: planta não linear real e modelo do controlador linearizado).

*offset*, ou seja, o controlador realmente corrige o erro de modelagem entre planta e modelo através da inclusão dos modificadores.

Como pode ser visto a partir da equação (175c), a modificação do modelo é realizada pela compensação linear feita pela adição de termos compostos por modificadores no modelo original. Pode-se ver em Figuras 64 e 65 a evolução dos termos  $\lambda_{u,k}^T(u - \bar{u}(k))$  e  $\epsilon$  em cada período de amostragem. Note que:

- (i) a Figura 65 mostra que modificadores de primeira ordem ( $\epsilon$ ) são perturbados em cada mudança de referência, mas sempre convergem ao passar do tempo;
- (ii) na Figura 64 os modificadores de segunda ordem ( $\lambda_{u,k}^T$ ), que compõem os gráficos dados por  $\lambda_{u,k}^T(u - \bar{u}(k))$ , complementam os valores dos modificadores  $\epsilon$  apenas durante o transiente, tendendo a zero sempre que  $\epsilon$  converge. A soma dos valores destes dois gráficos é igual ao erro entre o modelo e a planta em cada instante  $k$ .

Portanto, o controlador MPC Econômico de uma Camada é um controlador com *Offset-Free* e com todas as vantagens do chamado MPC para Tracking, como a estabilidade, factibilidade recursiva e convergência, inclusive no caso de mudanças na função de custo econômico.




Figura 63 – Saída do Sistema e Setpoints ótimos - Sistema controlado pelo Controlador MPC Econômico de uma Camada com erro de modelagem: planta não linear real e modelo do controlador linearizado.




Figura 64 – Valor da compensação do termo  $\lambda_{u,k}^T(u - \bar{u}(k))$




Figura 65 – Valor da compensação de  $\epsilon(k)$

#### 7.4 APLICAÇÃO DO CONTROLADOR MPC ECONÔMICO DE UMA CAMADA - CAMPO SOLAR DE GRANDE PORTE

O Controlador proposto nesta tese foi aplicado ao sistema apresentado no capítulo 3 denominado de Campo Solar de Grande Porte na configuração paralelo, como pode ser visto na Figura 66, cujo objetivo é o de manter a temperatura da mistura dos 4 setores do campo em um determinado valor. O modelo de planta utilizado nesta simulação é o modelo não linear descrito pela função 12 mostrada no capítulo 3. Entretanto, o controlador MPC Econômico de uma Camada utiliza um modelo linear do sistema, linearizado<sup>4</sup> no ponto de equilíbrio de  $m = 3 \text{ l/s}$ ,  $I = 800 \text{ W/m}^2$ ,  $T_i = 50 \text{ }^\circ\text{C}$ ,  $T_a = 10 \text{ }^\circ\text{C}$ , sendo que tal diferença entre modelos pode apresentar dificuldades de atingir o objetivo econômico (neste caso, seguimento de setpoint).

A função econômica do MPC Econômico de uma Camada utilizada para este exemplo é

$$J = \|y - y_{sp}\|^2 \quad (179)$$

de forma que o controlador deve levar o sistema ao setpoint ótimo  $y_{sp}$  de  $70 \text{ }^\circ\text{C}$ .

Para poder comparar a eficiência da utilização do controlador MPC Econômico de uma Camada, foram simulados dois cenários: o primeiro *sem* a utilização dos adaptadores MA e o segundo *com* os adaptadores MA que corrigem o modelo. As perturbações utilizadas neste exemplo são as mesmas que foram utilizadas no exemplo do capítulo 3 e são mostradas nas Figuras 67 e 68.

<sup>4</sup> Para mais detalhes sobre a linearização deste sistema, veja o trabalho de D. Lima *et al.* (2015)




Figura 66 – Sistema de um Campo Solar de Grande Porte




Figura 67 – Irradiações para os quatro setores do campo solar.




Figura 68 – Temperatura de entrada ( $T_i$ ) e Temperatura ambiente ( $T_a$ ) para os quatro setores do campo solar.

#### 7.4.1 Cenário 1 - Controlador sem a utilização dos Modificadores MA

Neste cenário foi utilizado o MPC Econômico de uma Camada sem o uso dos Modificadores (MA). A Figura 69 mostra o resultado para o cenário 1 da temperatura dos quatro setores do campo de grande porte. A Figura 70 mostra as ações de controle (vazões) de cada setor do campo para o cenário 1. E, por último, a Figura 71 mostra a temperatura da mistura dos quatro setores do campo, cujo valor de referência é  $70\text{ }^{\circ}\text{C}$ .

Como esperado, o sistema apresenta bom resultado no que diz respeito ao seguimento de referência na saída, uma vez que a planta não tem características altamente não lineares.

#### 7.4.2 Cenário 2 - Controlador com a utilização dos Modificadores MA

Neste cenário foi utilizado o MPC Econômico de uma Camada com o uso dos Modificadores (MA). Da mesma forma que no cenário anterior, os resultados para o cenário 2 são apresentados nas Figuras 72, 73 e 74 que mostram a temperatura dos quatro setores, as ações de controle e a temperatura da mistura, respectivamente.

Para comparar o desempenho do controlador proposto, a Figura 75 mostra a saída do sistema para ambos os cenários, onde pode-se observar que o controlador do cenário 2 (com MA) apresenta valores mais próximos da referência. Para poder mensurar tais resultados, a Tabela 14 apresenta o erro médio absoluto (Erro Médio Absoluto (EMA)) para a referência de ambos cenários. Na mesma Tabela mostra-se o índice de variação total do controlador (TV) para mensurar o esforço de controle em ambos os casos.

As Figuras 76 e 77 mostram os valores dos termos dos modificadores de segunda ordem ( $\lambda_{u,k}^T$ ) e de primeira ordem  $\epsilon$ , respectivamente. A soma dos valores destes dois gráficos é igual ao erro entre a temperatura do modelo e da planta em cada instante  $k$ .






Figura 69 – Temperatura dos quatro setores do campo de grande porte para o cenário 1

Tabela 14 – Índices de desempenho para os cenários 1 e 2

Cenário	EMA	TV
1 ( <i>semMA</i> )	0.6273	145.08
2 ( <i>comMA</i> )	0.6590	150.64

<sup>3</sup>Índices de desempenho:  $TV = \sum |\Delta U(k)|$  ;  $EMA = \sum |ref(k) - Y(k)|$ .




Figura 70 – Vazão dos quatro setores do campo de grande porte para o cenário 1




Figura 71 – Temperatura final do campo de grande porte para o cenário 1




Figura 72 – Temperatura dos quatro setores do campo de grande porte para o cenário 2

Verifica-se, portanto, que o controlador MPC Econômico de uma Camada apresenta, para este caso, uma redução do erro médio absoluto em aproximadamente 5% para o seguimento de referência quando comparado ao MPC sem modificadores. O incremento da performance é devido às propriedades do controlador proposto que, mesmo usando um modelo linearizado, permitem adaptá-lo (com a inclusão dos modificadores) e minimizar o erro entre planta o modelo (*mismatch error*). Por outro lado, devido às constantes variações das perturbações do sistema, o controlador não alcança o regime permanente propriamente dito, impossibilitando a convergência e a visualização do chamado *offset-free* como no exemplo dos 4 tanques. Apesar disso, nota-se que o controlador consegue melhorar sensivelmente o desempenho do sistema em termos de seguimento de referência, como visto na Figura 75 e na Tabela 14. Por outro lado, e como era esperado, essa busca por minimizar o erro de seguimento de referência gera um maior esforço de controle, que pode ser medido através do índice TV (*total variation*), também mostrado na Tabela 14, e que teve um aumento de aproximadamente 3.5%.




Figura 73 – Vazão dos quatro setores do campo de grande porte para o cenário 2




Figura 74 – Temperatura final do campo de grande porte para o cenário 2




Figura 75 – Temperatura final do campo de grande porte para os cenários 1 e 2





Figura 76 – Valor da compensação do termo  $\lambda_{u,k}^T(u - \bar{u}(k))$

Figura 77 – Valor da compensação de  $\epsilon(k)$ 

## 7.5 COMENTÁRIOS FINAIS DO CAPÍTULO

O Controlador proposto neste capítulo é um controlador MPC que, além das garantias de estabilidade e factibilidade mesmo frente a mudanças na função econômica do controlador, possui garantia de convergência ao ponto de operação ótimo da *planta real*, ainda que o modelo do controlador seja impreciso. Esta característica é alcançada com a utilização da técnica de adaptação via modificadores, resultando em um controlador livre de *offset*. É um controlador com implementação simplificada e que permite compensar fenômenos não modelados, como erro de modelagem e perturbações não modeladas, o que o torna um controlador com características estocásticas de fácil implementação. Dois estudos de caso foram apresentados para ilustrar as qualidades da estratégia proposta.

## 8 CONCLUSÕES

Nesta tese foram abordados temas ligados ao controle e gestão da energia proveniente de fontes renováveis. Foram estudadas as características estocásticas das fontes renováveis e explorados métodos para enfrentar as dificuldades decorrentes de tais fontes. A tese pode ser dividida em duas partes: a primeira apresenta resultados da investigação de soluções com base em estratégias de controle preditivo para problemas práticos na área de energias renováveis sem a preocupação de analisar a estabilidade de forma analítica. A segunda é estudar os aspectos relativos às condições de estabilidade dos sistemas controlados, buscando agregar o rigor teórico à possibilidade de aplicação em sistemas reais de grande porte.

As principais contribuições desta tese são apresentadas a seguir:

### **Modelagem e análise da topologia de uma planta heliotérmica**

Modelagem de uma planta heliotérmica controlada por um MPC para investigar os efeitos de mudanças na topologia do sistema analisando a quantidade de energia captada pelas diferentes configurações. Foi analisado o comportamento de dois sistemas: coletores em série e em paralelo, sendo que os resultados apresentaram uma diferença considerável, demonstrando que a configuração em paralelo tem vantagens pela possibilidade de desativar campos individualmente. Por outro lado, apesar de haver vários trabalhos acadêmicos que exploram a aplicação de controladores preditivos em sistemas heliotérmicos, a análise feita neste trabalho é relevante, principalmente porque não há informações claras sobre quais estratégias de controle são utilizadas pelos fabricantes de sistemas heliotérmicos vendidos comercialmente.

### **Uso de técnicas estocásticas em uma planta heliotérmica**

Adicionalmente, investigou-se a utilização de técnicas probabilísticas para enfrentar a estocasticidade proveniente da irradiação solar e seus efeitos em um sistema heliotérmico controlado por um controlador MPC. Os resultados mostraram que o uso das restrições probabilísticas permite que o sistema garanta, de forma probabilística, o atendimento das restrições, mesmo com a dificuldade enfrentada pela estocasticidade da fonte de energia.

### **Uso de técnicas estocásticas para o controle de uma usina de cana de açúcar**

Apresentou-se um estudo de caso com dados reais onde utilizam-se as restrições probabilísticas para enfrentar a dificuldade de controlar uma usina de cana de açúcar do ponto de vista de uma unidade de geração de energia híbrida. Nessa usina foram agregadas várias fontes de energia renovável de forma que a usina foi modelada como uma microrrede sujeita a diversas restrições operacionais. Tais restrições devem ser atendidas a despeito do comportamento estocástico da demanda de energia e das fontes de energia renovável. O uso das restrições

probabilísticas permite que o sistema lide melhor com a possível violação das restrições, dentre elas o não atendimento da demanda contratada evitando que o sistema opere em uma faixa economicamente inviável.

### **Uso de técnicas de controle hierárquico para o controle de várias usinas de cana de açúcar**

Um outro estudo de caso foi apresentado no qual trata-se de um conjunto de usinas de cana de açúcar que, utilizando técnicas de controle hierárquico, devem cooperar para atingir os objetivos globais de produção e fornecimento de energia. O ponto principal desta contribuição reside na aplicação prática da abordagem hierárquica *RTO - MPC* para um problema real no contexto da indústria de cana-de-açúcar brasileira em que há cooperação entre unidades geradoras com um contrato único de fornecimento de energia para a rede externa.

### **Proposta de controlador MPC Econômico de uma Camada com Offset-Free**

Por último, outra contribuição desta tese é o desenvolvimento de uma proposta de controlador MPC Econômico de uma camada que permite, através da utilização de técnicas de RTO, adaptar o problema de otimização de forma a contornar os efeitos de dinâmicas não modeladas e, de certa forma, adaptar o modelo para que o ótimo real da planta convirja ao ótimo do modelo utilizado pelo controlador.

Como resultado obteve-se uma estratégias de controle MPC que leva em conta aspectos econômicos e estocásticos dos sistemas de geração de energia agregando o rigor teórico da análise das condições de estabilidade no sentido de possibilitar a sua aplicação à realidade, principalmente, à dos sistemas de geração de energia. Tal contribuição aplica-se a sistemas de controle hierárquico com a vantagem de permitir que o controlador convirja para o ótimo da planta real, ainda que na presença de dinâmicas não modeladas.

## 8.1 LISTA DE PUBLICAÇÕES

No contexto do tema de controle preditivo com características estocásticas aplicado a sistemas de geração de energia com fontes renováveis, as contribuições deste trabalho em forma de publicações até o momento são:

1. [VERGARA DIETRICH, J. D.](#); [NORMEY-RICO, J. E.](#); [BERENGUEL, M.](#); [ROCA, L.](#) Controle de temperatura em campos solares de grande porte utilizando a abordagem do PN MPC - Practical Nonlinear Model Predictive Control. **Congresso Brasileiro de Automática**, Vitória, Espírito Santo, 2016.
2. [VERGARA DIETRICH, J. D.](#); [NORMEY-RICO, J. E.](#); [MENDES, P. R. da C.](#); [BORDONS, C.](#) Abordagem estocástica para o controle de temperatura de campos solares de grande



- porte - Restrições probabilísticas. **Simpósio Brasileiro de Automação Inteligente**, Porto Alegre, Rio Grande do Sul, 2017.
3. CANI, A. A.; MENDES, P. R. da C.; [VERGARA DIETRICH, J. D.](#); NORMEY-RICO, J. E.; BORDONS, C. Economic Viability Analysis of a Hybrid Power System Including Renewable Sources in the Sugar Cane Industry. **Simpósio Brasileiro de Automação Inteligente**, Porto Alegre, Rio Grande do Sul, 2017.
  4. [VERGARA DIETRICH J. D.](#); MORATO, M. M.; MENDES, P. R. da C.; NORMEY-RICO, J. E.; BORDONS, C. Advanced chance-constrained predictive control for the efficient energy management of renewable power systems. **Journal of Process Control**, 2017.
  5. MORATO, M. M.; [VERGARA DIETRICH J. D.](#); MENDES, P. R. da C.; NORMEY-RICO, J. E.; BORDONS, C. A Two-Layer EMS for Cooperative Sugarcane-based. **International Journal of Electrical and Power Systems**, 2019
  6. [VERGARA DIETRICH J. D.](#); Mirasierra, V.; Limón, D. A Modifier Adaptation Approach to the One-Layer MPCT. **IFAC World Congress**, 2020 (aceito).
  7. Mirasierra, V.; [VERGARA DIETRICH J. D.](#); Limón, D. Real-Time Optimization of Periodic Systems: A Modifier-Adaptation Approach. **IFAC World Congress**, 2020 (aceito).

## 8.2 TRABALHOS FUTUROS

O tema de geração de energia com fontes renováveis é um assunto que deve aumentar consideravelmente nos próximos anos, haja vista a tendência mundial do uso desse tipo de fontes de energia. Dessa forma, o estudo nesse âmbito do controle desses sistemas é um campo em aberto, com diversas possibilidades de pesquisa. Nesse sentido, lista-se a seguir algumas linhas de trabalhos futuros possíveis no âmbito desta tese.

- Comparar o método proposto de controle hierárquico para usinas de cana-de-açúcar com outras técnicas bem estabelecidas vistas na literatura.
- Implementar as soluções propostas nesta tese em plantas reais. Uma possibilidade é a utilização da planta heliotérmica montada nas dependências do Departamento de Automação e Sistemas (DAS) da UFSC, coordenada pelo professor Julio E. Normey Rico. Outra possibilidade é a implementação das técnicas na planta solar que está sendo projetada em parceria com a Petrobrás, na cidade de Macaé-RJ.
- Analisar a necessidade/viabilidade da utilização de técnicas probabilísticas na abordagem do controlador MPC Econômico de uma Camada proposto nesta Tese.
- Aplicar a abordagem do MPC Econômico de uma Camada para um problema como o caso de estudo da usina de cana-de-açúcar;

- 
- Aplicar a abordagem do MPC Econômico de uma Camada para um problema periódico complexo, como no caso do processo de produção de etanol;
  - Aplicar a abordagem do MPC Econômico de uma Camada para um problema industrial complexo.

## REFERÊNCIAS

ACKOOIJ, Wim Van. **Chance constrained programming: with applications in energy management**. 2013. Tese (Doutorado) – École Centrale Paris.

AGÊNCIA-BRASIL. **Banco de Informações de Geração**. Mai. 2015. Disponível em: <http://www.brasil.gov.br/infraestrutura/2012/06/brasil-pode-ser-exemplo-em-energia-renovavel>.

AGUIAR, R.J.; COLLARES-PEREIRA, M.; CONDE, J.P. Simple procedure for generating sequences of daily radiation values using a library of Markov transition matrices. **Solar Energy**, v. 40, n. 3, p. 269–279, 1988.

ALAMO, T; FERRAMOSCA, A; GONZALEZ, A H; LIMON, D; ODLOAK, D. A gradient-based strategy for integrating real time optimizer (RTO) with model predictive control (MPC). In: PROCEEDINGS of the 4th IFAC Nonlinear Model Predictive Control Conference. Noordwijkerhout, NL: [s.n.], 2012. P. 33–38.

ALAMO, Teodoro; FERRAMOSCA, Antonio; GONZÁLEZ, Alejandro H.; LIMON, Daniel; ODLOAK, Darci. A gradient-based strategy for the one-layer RTO + MPC controller. **Journal of Process Control**, v. 24, n. 4, p. 435–447, 2014. DOI: <https://doi.org/10.1016/j.jprocont.2014.02.018>.

ALVAREZ, Luz A.; ODLOAK, Darci. Robust integration of real time optimization with linear model predictive control. **Computers & Chemical Engineering**, v. 34, n. 12, p. 1937–1944, 2010. 10th International Symposium on Process Systems Engineering, Salvador, Bahia, Brasil, 16-20 August 2009. DOI: <http://dx.doi.org/10.1016/j.compchemeng.2010.06.017>.

AMRIT, Rishi. **Optimizing Process Economics in Model Predictive Control**. 2011. Tese (Doutorado) – University of Wisconsin - Madison.

ANDERSON, D.; LEACH, M. Harvesting and redistributing renewable energy: on the role of gas and electricity grids to overcome intermittency through the generation and storage of hydrogen. **Energy Policy** 32, p. 1603–1614, 2004.

ANEEL. **Matriz energética brasileira**. 6 ago. 2019. Disponível em: <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.cfm>. Acesso em: 30 nov. 2019.

- ANGELI, D.; AMRIT, R.; RAWLINGS, J. B. On Average Performance and Stability of Economic Model Predictive Control. **IEEE Transactions on Automatic Control**, v. 57, n. 7, p. 1615–1626, jul. 2012.
- B. CHACHUAT, B. Srinivasan; D. BONVIN. Adaptation strategies for real-time optimization. **Computers & Chemical Engineering**, v. 33, n. 10, p. 1557–1567, 2009.
- BÁEZ-GONZÁLEZ, Pablo; DEL REAL, A.J.; RIDAO, M.A.; BORDONS, Carlos. Day-ahead economic optimization of energy use in an olive mill. **Control Engineering Practice**, Pergamon, v. 54, p. 91–103, 2016.
- BECERRA, M.; ROBERTS, P.D.; GRIFFITHS, G.W. Novel developments in process optimisation using predictive control. **Journal of Process Control**, 1998.
- BIEGLER, L.T. Technology Advances for Dynamic Real-Time Optimization. **Computer Aided Chemical Engineering**, v. 27, p. 1–6, 2009. 10th International Symposium on Process Systems Engineering: Part A. DOI: [http://dx.doi.org/10.1016/S1570-7946\(09\)70220-2](http://dx.doi.org/10.1016/S1570-7946(09)70220-2).
- BITMEAD, R. R.; GEVERS, M.; WERTZ, V. **Adaptive optimal control: The thinking mans GPC**. Englewood Cliffs, NJ: Prentice-Hall, 1990.
- BLANCHINI, F.; MIANI, S. Any domain of attraction for a linear constrained system is a tracking domain of attraction. **SIAM Journal on Control and Optimization**, v. 38, p. 971–994, 2000.
- BORBELY, A. M.; KREIDER, J. F. **Distributed Generation: The Power Paradigm for the New Millenium**. Boca Raton: CRC Press, 2001.
- BOUZID, Allal M; GUERRERO, Josep M; CHERITI, Ahmed; BOUHAMIDA, Mohamed; SICARD, Pierre; BENGHANEM, Mustapha. A survey on control of electric power distributed generation systems for microgrid applications. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 44, p. 751–766, 2015.
- BOYD, Stephen; VANDENBERGHE, Lieven. **Convex Optimization**. New York, NY, USA: Cambridge University Press, 2004.

BUI, Van-Hai; HUSSAIN, Akhtar; KIM, Hak-Man. A multiagent-based hierarchical energy management strategy for multi-microgrids considering adjustable power and demand response. **IEEE Transactions on Smart Grid**, IEEE, v. 9, n. 2, p. 1323–1333, 2018.

BULLICH-MASSAGUÉ, Eduard; DÍAZ-GONZÁLEZ, Francisco; ARAGÜÉS-PEÑALBA, Mònica; GIRBAU-LLISTUELLA, Francesc; OLIVELLA-ROSELL, Pol; SUMPER, Andreas. Microgrid clustering architectures. **Applied Energy**, Elsevier, v. 212, p. 340–361, 2018.

C.M. CIRRE; M. BERENGUEL; L. VALENZUELA; E.F. CAMACHO. Feedback linearization control for a distributed solar collector field. **Control Engineering Practice**, IFAC World Congress, Praga, Republica Checa, n. 15, p. 1533–1544, 2007.

CAMACHO, E.; BORDONS, C. **Model predictive control**. London: Springer, 2004. (Advanced Textbooks in Control and Signal Processing).

CAMPOS, Mario Cesar M. Massa de; CARVALHO GOMES, Marcos Vinicius de; PEREZ, José Manuel Gonzalez Tubio. **Controle avançado e otimização na indústria do petróleo**. [S.l.]: Interciência, 2013.

CANNON, M.; KOUVARITAKIS, B.; WU, X. Probabilistic constrained MPC for multiplicative and additive stochastic uncertainty. **IEEE Transactions on Automatic Control**, v. 54, n. 7, p. 1626–1632, jul. 2009. DOI: 10.1109/TAC.2009.2017970.

CHARNES, A.; COOPER, W. W. Deterministic Equivalents for Optimizing and Satisficing under Chance Constraints. In: **Economic Models, Estimation and Risk Programming: Essays in Honor of Gerhard Tintner**. Edição: Karl A. Fox, Jati K. Sengupta e G. V. L. Narasimham. Berlin, Heidelberg: Springer Berlin Heidelberg, 1969. P. 425–455.

CHRISTO, T. M.; BERNABÉ, T. P.; FARDIN, J. F.; SIMONETTI, D. S. L. Wavelets e Redes Neurais aplicadas a Previsão de Recurso Eólico (Wavelets and Neural Networks applied to Prediction of Wind Resources). In: CONGRESSO BRASILEIRO DE AUTOMÁTICA.

CLARKE, D. W.; SCATTOLINI, R. Constrained receding-horizon predictive control. **IEE Proceedings D - Control Theory and Applications**, v. 138, n. 4, p. 347–354, jul. 1991. DOI: 10.1049/ip-d.1991.0047.

COSTA MENDES, Paulo Renato da. **Energy management of renewable energy based microgrids**. 2016. Tese (Doutorado) – Universidade Federal de Santa Catarina.

COSTA, Marcus V. Americano da; CRUZ, V. M.; NORMEY-RICO, Julio Elias. Modeling, simulation and control of a distillation unit in an ethanol-producing plant (Text in portuguese), 2012.

COSTA, Marcus V. Americano da; PASAMONTES, Manuel; NORMEY-RICO, Julio E.; GUZMÁN, José L.; BERENGUEL, Manuel. Advanced Control Strategy Combined with Solar Cooling for Improving Ethanol Production in Fermentation Units. **Industrial & Engineering Chemistry Research**, v. 53, n. 28, p. 11384–11392, 2014. DOI: 10.1021/ie403286m. Disponível em: <http://dx.doi.org/10.1021/ie403286m>.

D. LIMA; J. NORMEY-RICO; T. SANTOS. Temperature control in a solar collector field using Filtered Dynamic Matrix Control. **ISA Transactions**, 2015.

DAMODAR GUJARATI, Dawn Porter. **Basic Econometrics**. 5. ed. [S.l.]: McGraw-Hill Education, 2008.

DELL, R.; RAND, D. Energy storage a key technology for global energy sustainability. **J. Power Sources** 100, p. 2–17, 2001.

DURBECK, R. C. **Principles for simplification of optimising control models**. 1965. Tese (Doutorado) – Case Western Reserve University, U.S.A.

E. CAMACHO; C. BORDONS. **Model Predictive Control**. [S.l.]: Springer, 2007.

ELLIS, Matthew; DURAND, Helen; CHRISTOFIDES, Panagiotis D. A tutorial review of economic model predictive control methods. **Journal of Process Control**, v. 24, n. 8, p. 1156–1178, 2014. Economic nonlinear model predictive control. DOI: <https://doi.org/10.1016/j.jprocont.2014.03.010>.

FARINA, Marcello; GIULIONI, Luca; SCATTOLINI, Riccardo. Stochastic linear Model Predictive Control with chance constraints—A review. **Journal of Process Control**, Elsevier, v. 44, p. 53–67, 2016.

FARSADI, Murtaza; HOSSEINNEJAD, Hadi; DIZAJI, Tohid Sattarpour. Solving unit commitment and economic dispatch simultaneously considering generator constraints by using nested PSO. In: IEEE. 9TH International Conference on Electrical and Electronics Engineering. [S.l.: s.n.], 2015. P. 493–499.

FERRAMOSCA, Antonio. **MODEL PREDICTIVE CONTROL OF SYSTEMS WITH CHANGING SETPOINTS**. 2011. Tese (Doutorado) – Universidad de Sevilla.

FERRAMOSCA, Antonio; LIMON, Daniel; CAMACHO, Eduardo F. Economic MPC for a Changing Economic Criterion for Linear Systems. **IEEE Transactions on Automatic Control**, 2014.

FERRARI-TRECATE, G.; GALLESTEY, E.; LETIZIA, P.; SPEDICATO, M.; MORARI, M.; ANTONINE, M. Modeling and control of co-generation power plants: a hybrid system approach. **IEEE Transactions on Control Systems Technology**, v. 12, n. 5, p. 694–705, 2004. DOI: 10.1109/TCST.2004.826958.

FINDEISEN, W; FN, Bailey; BRDYS, M; MALINOWSKI, K; TATJEWSKI, P; WOZNIAK, A. **Control and Coordination in Hierarchical Systems**. [S.l.: s.n.], 1980.

FINDEISEN, Władysław. **Decentralized and Hierarchical Control, Decision Making, Under Consistency Or Disagreement of Interest**. [S.l.: s.n.], 1980.

GALUS, Matthias D; ART, GA Simon. A hierarchical, distributed PEV charging control in low voltage distribution grids to ensure network security. In: IEEE. POWER and Energy Society General Meeting, 2012 IEEE. [S.l.: s.n.], 2012. P. 1–8.

GARCIA-TORRES, F.; BORDONS, C. Optimal Economical Schedule of Hydrogen-Based Microgrids With Hybrid Storage Using Model Predictive Control. **Industrial Electronics, IEEE Transactions on**, v. 62, n. 8, p. 5195–5207, ago. 2015. DOI: 10.1109/TIE.2015.2412524.

GARCIA-TORRES, Felix; BORDONS, Carlos; RIDAO, Miguel A. Optimal economic schedule for a network of microgrids with hybrid energy storage system using distributed model predictive control. **IEEE Transactions on Industrial Electronics**, IEEE, v. 66, n. 3, p. 1919–1929, 2019.

GEIDL, Martin. **Integrated modeling and optimization of multi-carrier energy systems**. 2007. Tese (Doutorado) – ETH Zurich.

GEIDL, Martin; KOEPEL, Gaudenz; FAVRE-PERROD, Patrick; KLOCKL, Bernd; ANDERSSON, Goran; FROHLICH, Klaus. Energy hubs for the future. **IEEE Power and Energy magazine**, IEEE, v. 5, n. 1, p. 24–30, 2007.

GILBERT, E. G.; TAN, K. Linear systems with state and control constraints: The theory and application of maximal output admissible sets. **IEEE Transactions on Automatic Control**, v. 36, p. 1008–1020, 1991.

GILBERT, E.; KOLMANOVSKY, I.; TAN, K. Nonlinear control of discrete-time linear systems with state and control constraints: A reference governor with global convergence properties. In: IN Proceedings of the CDC. [S.l.: s.n.], 1994. 110–122 vol.19.

GONZÁLEZ, J. R. P. **Libro Blanco de la Automatización y Control en la Industria de la Caña de Azúcar**. [S.l.: s.n.], 2011.

GREENWELL, W.; VAHIDI, A. Predictive Control of Voltage and Current in a Fuel Cell-Ultracapacitor Hybrid. **IEEE Transactions on Industrial Electronics**, v. 57, n. 6, p. 1954–1963, 2010. DOI: 10.1109/TIE.2009.2031663.

GROSSO, JM; OCAMPO-MARTÍNEZ, Carlos; PUIG, V; JOSEPH, B. Chance-constrained model predictive control for drinking water networks. **Journal of Process Control**, Elsevier, v. 24, n. 5, p. 504–516, 2014.

GRÜNE, Lars; PANNEK, Jürgen. **Nonlinear Model Predictive Control: Theory and Algorithms**. London: Springer-Verlag, 2011.

HAMILTON, J. D. **Time series analysis**. [S.l.]: Princeton University Press, 1994.

HAN, Yang; LI, Hong; SHEN, Pan; COELHO, Ernane Antônio Alves; GUERRERO, Josep M. Review of active and reactive power sharing strategies in hierarchical controlled microgrids. **IEEE Transactions on Power Electronics**, IEEE, v. 32, n. 3, p. 2427–2451, 2016.

HERNÁNDEZ, Reinaldo; ENGELL, Sebastian. Economics Optimizing Control with Model Mismatch Based on Modifier Adaptation. **IFAC-PapersOnLine**, v. 52, n. 1, p. 46–51, 2019. 12th IFAC Symposium on Dynamics and Control of Process Systems, including Biosystems DYCOPS 2019.

HOOSHMAND, Ali; ASGHARI, Babak; SHARMA, Ratnesh. A novel cost-aware multi-objective energy management method for microgrids. In: IEEE. INNOVATIVE Smart Grid Technologies (ISGT), 2013 IEEE PES. [S.l.: s.n.], 2013. P. 1–6.

HOVGAARD, Tobias Gybel; LARSEN, Lars FS; JØRGENSEN, John Bagterp. Robust economic MPC for a power management scenario with uncertainties. In: IEEE. DECISION



and Control and European Control Conference (CDC-ECC), 2011 50th IEEE Conference on. [S.l.: s.n.], 2011. P. 1515–1520.

ILOG, IBM. **CPLEX**. [S.l.: s.n.], 2007.

TECHNOLOGY Roadmap: Solar Thermal Electricity. <https://www.iea.org/publications/freepublications/publication/technology-roadmap-solar-thermal-electricity-2014-edition.html>. International Energy Agency. Set. 2014.

J. F. FORBES; T. E. MARLIN; J. F. MACGREGOR. Model adequacy requirements for optimizing plant operations. **Computers & Chemical Engineering**, v. 18, 18(6), p. 497–510, 6 1994.

JADBABAIE, A.; YU, J.; HAUSER, J. Unconstrained receding-horizon control of nonlinear systems. **IEEE Transactions on Automatic Control**, v. 46, n. 5, p. 776–783, 2001.

JIANZHE, Liu; CHEN, Hua; ZHANG, Wei; YURKOVICH, Benjamin; RIZZONI, Giorgio. Energy Management Problems Under Uncertainties for Grid-Connected Microgrids: a Chance Constrained Programming Approach. **Transactions on Smart Grids**, 2016.

JOHANSSON, Karl Henrik. The quadruple-tank process. **IEEE Trans. Automatic Control**, 2000.

JOHN R. BIRGE, François Louveaux. **Introduction to Stochastic Programming**. Corrected. [S.l.]: Springer, 1997.

KADAM, Jitendra V.; MARQUARDT, Wolfgang. Integration of Economical Optimization and Control for Intentionally Transient Process Operation. In: **Assessment and Future Directions of Nonlinear Model Predictive Control**. Edição: Rolf Findeisen, Frank Allgöwer e Lorenz T. Biegler. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. P. 419–434.

KATIRAEI, Farid; IRAVANI, Mohammad Reza. Power management strategies for a microgrid with multiple distributed generation units. **IEEE Transactions on power systems**, IEEE, v. 21, n. 4, p. 1821–1831, 2006.

KAZARLIS, Spyros A; BAKIRTZIS, AG; PETRIDIS, Vassilios. A genetic algorithm solution to the unit commitment problem. **IEEE transactions on power systems**, IEEE, v. 11, n. 1, p. 83–92, 1996.

KENDALL, M.G.; BUCKLAND, W.R.; INSTITUTE, International Statistical. **A dictionary of statistical terms**. [S.l.]: Hafner Pub. Co., 1971. (A Dictionary of Statistical Terms: Prepared for the International Statistical Institute).

LASSETER, Robert H. Microgrid. In: IEEE. PROC. Int. of Power Engineering Society Winter Meeting. [S.l.: s.n.], 2002.

LEGRY, M; COLAS, F; SAUDEMONT, C; DIEULOT, JY; DUCARME, O. A Two-layer Model Predictive Control Based Secondary Control with Economic Performance Tracking for Islanded Microgrids. In: IEEE. IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society. [S.l.: s.n.], 2018. P. 77–82.

LIANG, Hao; ZHUANG, Weihua. Stochastic Modeling and Optimization in a Microgrid: A Survey. **energies**, p. 2027–2050, 2014. DOI: doi:10.3390/en7042027.

LIMON, D.; ALAMO, T.; PEREIRA, M.; FERRAMOSCA, A.; GONZALES, A.H.; ODLOAK, D. Integrating the RTO in the MPC: an adaptive gradient-based approach. In: ECC. [S.l.: s.n.], jul. 2013.

LIMON, D; ALVARADO, I; ALAMO, T; CAMACHO, E F. MPC for tracking of piece-wise constant references for constrained linear systems. **Automatica**, v. 44, p. 2382–2387, 2008.

LIMON, Daniel. **Control predictivo de sistemas no lineales con restricciones: estabilidad y robustez**. 2002. Tese (Doutorado) – Universidad de Sevilla.

LIMON, Daniel; ALAMO, Teodoro; MUÑOZ DE LA PEÑA, D; ZEILINGER, Melanie Nicole; JONES, Colin; PEREIRA, Mario. MPC for tracking periodic reference signals. In: EPFL-CONF-181940. PROCEEDINGS of the IFAC Conference on Nonlinear Model Predictive Control. [S.l.: s.n.], 2012.

LOFBERG, J. YALMIP: A Toolbox for Modeling and Optimization in MATLAB. **IEEE International Symposium on Computer Aided Control Systems Design**, p. 284–289, 2004. DOI: 10.1109/CACSD.2004.1393890.

LUBIN, Miles; DVORKIN, Yury; BACKHAUS, Scott. A Robust Approach to Chance Constrained Optimal Power Flow With Renewable Generation. **Transactions Power Systems**, 2015.

- LUBIN, Miles; DVORKIN, Yury; BACKHAUS, Scott. A robust approach to chance constrained optimal power flow with renewable generation. **IEEE Transactions on Power Systems**, IEEE, v. 31, n. 5, p. 3840–3849, 2016.
- M. PASAMONTES; J.D. ÁLVAREZ; J.L. GUZMÁN; M. BERENGUEL; E.F. CAMACHO. Hybrid modeling of a solar-thermal heating facility. **Solar Energy**, n. 97, p. 557–590, 2013.
- MAEDER, Urban; BORELLI, Francesco; MORARI, Manfred. Linear offset-free Model Predictive Control. **Automatica**, p. 2214–2222, 2009.
- MAJUMDER, Ritwik; GHOSH, Arindam; LEDWICH, Gerard; ZARE, Firuz. Load sharing and power quality enhanced operation of a distributed microgrid. **IET Renewable Power Generation**, IET, v. 3, n. 2, p. 109–119, 2009.
- MARCHETTI, A.; CHACHUAT, B.; BONVIN, D. Modifier-Adaptation Methodology for Real-Time Optimization. **Industrial & Engineering Chemistry Research**, 2009.
- MARCHETTI, A.; FERRAMOSCA, Antonio; GONZÁLES, A.H. Steady-state target optimization designs for integrating real-time optimization and model predictive control. **Journal of Process Control**, 2013.
- MARCHETTI, A.; LUPPI, P.; BASUALDO, M. Real-Time Optimization via Modifier Adaptation Integrated with Model Predictive Control. In: IFAC 2011. [S.l.: s.n.], 2011.
- MARCHETTI, Alejandro G.; FRANÇOIS, Grégory; FAULWASSER, Timm; BONVIN, Dominique. Modifier Adaptation for Real-Time Optimization - Methods and Applications. **Processes**, v. 4, n. 4-55, 2016.
- MATHWORKS. **Matlab**. [S.l.: s.n.], 2009.
- MATHWORKS. **Matlab**. [S.l.: s.n.], 2017.
- MAYNE, D.Q.; RAWLINGS, J.B.; RAO, C.V.; SCOKAERT, P.O.M. Constrained model predictive control: Stability and optimality. **Automatica**, v. 36, n. 6, p. 789–814, 2000.
- MAYNE, David. Robust and stochastic model predictive control: Are we going in the right direction? **Annual Reviews in Control**, v. 41, p. 184–192, 2016. DOI: <http://dx.doi.org/10.1016/j.arcontrol.2016.04.006>.

MAYNE, David Q. Model predictive control: Recent developments and future promise. **Automatica**, v. 50, n. 12, p. 2967–2986, 2014.

MEIBOM, Peter; BARTH, Rüdiger; HASCHKE, Bernhard; BRAND, Heike; WEBER, Christoph; O MALLEY, Mark. Stochastic optimization model to study the operational impacts of high wind penetrations in Ireland. **IEEE Transactions on Power Systems**, IEEE, v. 26, n. 3, p. 1367–1379, 2011.

MENDES, P. R. C. **Predictive Control for Energy Management of Renewable Energy Based Microgrids**. 2016. Tese (Doutorado) – Universidade Federal de Santa Catarina.

MENDES, P. R. C.; ISORNA, L. V.; BORDONS, C.; NORMEY-RICO, J. E. Energy management of an experimental microgrid coupled to a V2G system. **Journal of Power Sources**, Elsevier, p. 702–713, 2016.

MENDES, P. R. C.; MAESTRE, Jose M; BORDONS, Carlos; NORMEY-RICO, Julio E. A practical approach for hybrid distributed MPC. **Journal of Process Control**, Elsevier, v. 55, p. 30–41, 2017.

MESBAH, A. Stochastic Model Predictive Control: An Overview and Perspectives for Future Research. **IEEE Control Systems**, v. 36, n. 6, p. 30–44, dez. 2016. DOI: 10.1109/MCS.2016.2602087.

MICHALSKA, H.; MAYNE, D. Q. Robust receding horizon control of constrained nonlinear systems. **IEEE Transactions on Automatic Control**, v. 38, n. 11, p. 1623–1633, nov. 1993. DOI: 10.1109/9.262032.

MINCHALA-AVILA, Luis I; GARZA-CASTAÑÓN, Luis E; VARGAS-MARTÍNEZ, Adriana; ZHANG, Youmin. A review of optimal control techniques applied to the energy management and control of microgrids. **Procedia Computer Science**, Elsevier, v. 52, p. 780–787, 2015.

MINISTÉRIO DE MINAS E ENERGIA, Governo Federal. **Resenha Energética Brasileira: Exercício de 2014**. [S.l.: s.n.], 2015. P. 6–19.

MOHANDÉS, Mohamed A; REHMAN, Shafiqur; HALAWANI, Talal O. A neural networks approach for wind speed prediction. **Renewable Energy**, Elsevier, v. 13, n. 3, p. 345–354, 1998.

MORATO, M. M.; MENDES, P. R. C.; BERTOL, D. W.; CEMBRANEL, D.; BORDONS, C.; NORMEY-RICO, J. E. Estudo de uma planta híbrida de geração de energia na indústria da cana-de-açúcar. In: CONGRESSO Brasileiro de Automática. [S.l.: s.n.], 2016.

MORATO, M. M.; MENDES, P. R. C.; NORMEY-RICO, J. E.; BORDONS, C. Advanced Control for Energy Management of Grid-Connected Hybrid Power Systems in the Sugar Cane Industry. In: IFAC. PROCEEDINGS of the 20th IFAC World Congress. [S.l.: s.n.], 2017.

MORATO, Marcelo M.; MENDES, P. R. C.; NORMEY-RICO, Julio E.; BORDONS, Carlos. Optimal operation of hybrid power systems including renewable sources in the sugar cane industry. English. **IET Renewable Power Generation**, v. 11, 1237–1245(8), 8 2017.

MORATO, Marcelo M.; REGNER, D. J.; MENDES, P. R. C.; NORMEY-RICO, Julio E.; BORDONS, Carlos. Fault Analysis, Detection and Estimation for a Microgrid via  $H_2/H_\infty$  LPV Observers. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 105, p. 823–845, 2019.

MORATO, Marcelo Menezes; COSTA MENDES, Paulo Renato da; BERTOL, Douglas Wildgrube; CEMBRANEL, Dandara; BORDONS, Carlos; NORMEY-RICO, Julio Elias. Estudo de uma planta híbrida de geração de energia na indústria da cana-de-açúcar. **Congresso Brasileiro de Automática**, 2016a.

MORATO, Marcelo Menezes; COSTA MENDES, Paulo Renato da; BORDONS, Carlos; NORMEY-RICO, Julio Elias. Optimization and Control of Hybrid Generation Power Systems Including Renewable Sources: Power Plants in the Sugar Cane Industry. **IET Renewable Power Generation**, 2016b.

MORATO, Marcelo Menezes; COSTA MENDES, Paulo Renato da; CANI, Alex Amadeu; NORMEY-RICO, Julio Elias; BORDONS, Carlos. Future Hybrid Local Energy Generation Paradigm for the Brazilian Sugarcane Industry Scenario. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 101, p. 139–150, 2018.

MORATO, Marcelo Menezes; COSTA MENDES, Paulo Renato da; NORMEY-RICO, Julio Elias; BORDONS, Carlos. Optimal operation of hybrid power systems including renewable sources in the sugar cane industry. English. **IET Renewable Power Generation**, Institution of Engineering e Technology, jan. 2017.

MORÉ, Jorge J. The Levenberg-Marquardt algorithm: implementation and theory. In: NUMERICAL analysis. [S.l.]: Springer, 1978. P. 105–116.

- MOSCA, E.; LEMOS, J. M.; ZHANG, J. Stabilizing I/O receding horizon control. In: 29TH IEEE Conference on Decision and Control. [S.l.: s.n.], dez. 1990. 2518–2523 vol.4. DOI: 10.1109/CDC.1990.203454.
- MUSKE, K. R. Steady-state target optimization in linear model predictive control. In: PROCEEDINGS of the 1997 American Control Conference. [S.l.: s.n.], jun. 1997. P. 3597–3601.
- NORMEY-RICO, J. E.; CAMACHO, E. **Control of dead-time processes**. London: Springer, 2007. (Advanced Textbooks in Control and Signal Processing).
- OLDEWURTEL, Frauke; PARISIO, Alessandra; JONES, Colin N; MORARI, Manfred; GYALISTRAS, Dimitrios; GWERDER, Markus; STAUCH, Vanessa; LEHMANN, Beat; WIRTH, Katharina. Energy efficient building climate control using stochastic model predictive control and weather predictions. In: IEEE. AMERICAN control conference. [S.l.: s.n.], 2010. P. 5100–5105.
- OLIVARES, Daniel E; CAÑIZARES, Claudio A; KAZERANI, Mehrdad. A centralized energy management system for isolated microgrids. **IEEE Transactions on Smart Grid**, v. 5, n. 4, p. 1864–1875, 2014.
- OLIVARES, Daniel E; LARA, Jose D; CAÑIZARES, Claudio A; KAZERANI, Mehrdad. Stochastic-predictive energy management system for isolated microgrids. **IEEE Transactions on Smart Grid**, IEEE, v. 6, n. 6, p. 2681–2693, 2015.
- OUAMMI, Ahmed; DAGDOUGUI, Hanane; DESSAINT, Louis; SACILE, Roberto. Coordinated model predictive-based power flows control in a cooperative network of smart microgrids. **IEEE Transactions on Smart grid**, IEEE, v. 6, n. 5, p. 2233–2244, 2015.
- P. D. ROBERTS. An algorithm for steady-state system optimization and parameter estimation, p. 719–734, 1979.
- P. TATJESKI. Iterative optimizing set-point control - The basic principle redesigned. In: IN Proc 15th World Congress of IFAC Barcelona. Barcelona, Spain: [s.n.], 2002.
- PALIZBAN, Omid; KAUHANIEMI, Kimmo. Hierarchical control structure in microgrids with distributed generation: Island and grid-connected mode. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 44, p. 797–813, 2015.

PARISINI, T.; ZOPPOLI, R. A receding-horizon regulator for nonlinear systems and a neural approximation. **Automatica**, v. 31, n. 10, p. 1443–1451, 1995. ISSN 0005-1098.

PARISIO, Alessandra; WIEZOREK, Christian; KYNTÄJÄ, Timo; ELO, Joonas; STRUNZ, Kai; JOHANSSON, Karl Henrik. Cooperative MPC-based energy management for networked microgrids. **IEEE Transactions on Smart Grid**, IEEE, v. 8, n. 6, p. 3066–3074, 2017.

PAWLOWSKI, A.; GUZMÁN, J. L.; RODRÍGUEZ, F.; BEREGUEL, M.; NORMEY-RICO, J. E. Predictive control with disturbance forecasting for greenhouse diurnal temperature control. In: IFAC Proceedings. [S.l.]: Elsevier, 2011.

PAWLOWSKI, A.; GUZMÁN, J. L.; RODRÍGUEZ, F.; BERENGUEL, M.; SÁNCHEZ, J. Application of time-series methods to disturbance estimation in predictive control problems. In: IEEE. IEEE International Symposium on Industrial Electronics. [S.l.: s.n.], 2010.

PETROLLESE, Mario. **OPTIMAL GENERATION SCHEDULING FOR RENEWABLE MICROGRIDS USING HYDROGEN STORAGE SYSTEMS**. 2015. Tese (Doutorado).

PINHEIRO, Joao; CUNHA, Sonia; GOMES, Gastao; CARVAJAL, Santiago. **Probabilidade e Estatística. Quantificando A Incerteza**. [S.l.: s.n.], 2012.

PLUCÊNIO, Augustinho. **Desenvolvimento de técnicas de controle não linear para elevação de fluídos multifásicos**. 2010. Tese (Doutorado) – Universidade Federal de Santa Catarina.

QIN, S.Joe; BADGWELL, Thomas A. A survey of industrial model predictive control technology. **Control Engineering Practice**, v. 11, n. 7, p. 733–764, 2003. DOI: [http://dx.doi.org/10.1016/S0967-0661\(02\)00186-7](http://dx.doi.org/10.1016/S0967-0661(02)00186-7).

RAO, Christopher V.; RAWLINGS, James B. Steady states and constraints in model predictive control. **AIChE Journal**, Wiley Subscription Services, Inc., A Wiley Company, v. 45, n. 6, p. 1266–1278, 1999. DOI: 10.1002/aic.690450612.

RAWLINGS, J. B.; ANGELI, D.; BATES, C. N. Fundamentals of Economic Model Predictive Control. In: PROCEEDINGS of the 51st IEEE Conference on Decision and Control (CDC). [S.l.: s.n.], 2012a. P. 3851–3861.

- RAWLINGS, J. B.; ANGELI, D.; BATES, C. N. Fundamentals of economic model predictive control. In: 51ST IEEE Conference on Decision and Control (CDC). [S.l.: s.n.], dez. 2012b. P. 3851–3861.
- REIKARD, Gordon. Predicting solar radiation at high resolutions: A comparison of time series forecasts. **Solar Energy**, v. 83, n. 3, p. 342–349, 2009.
- ROALD, L.; OLDEWURTEL, F.; KRAUSE, T.; ANDERSSON, G. Analytical reformulation of security constrained optimal power flow with probabilistic constraints. In: POWERTECH (POWERTECH), 2013 IEEE Grenoble. [S.l.: s.n.], jun. 2013. P. 1–6. DOI: 10.1109/PTC.2013.6652224.
- ROBERTS, P. D.; WILLIAMS, T. W. C. On an Algorithm for Combined System Optimisation and Parameter Estimation. In: IFAC Symposium on Identification and System Parameter Estimation. [S.l.: s.n.], 1980.
- ROCA, Lidia; BERENGUEL, Manuel; YEBRA, Luis; ALARCÓN-PADILLA, Diego C. Solar field control for desalination plants. **Solar Energy**, n. 82, p. 772–786, 2008.
- RODRIGUEZ-BLANCO, Tania; SARABIA, Daniel; PITARCHAND, J.L.; PRADA, C. de. Modifier Adaptation methodology based on transient and static measurements for RTO to cope with structural uncertainty. **Computers and Chemical Engineering**, n. 106, p. 480–500, 2017.
- SARTORI, Rafael. Controle preditivo economico em processos da indústria petroquímica, 2017.
- SCHWARM, Alexander T.; NIKOLAOU, Michael. Chance-Constrained Model Predictive Control. **AIChE Journal**, p. 1743–1752, 1999a.
- SCHWARM, Alexander T.; NIKOLAOU, Michael. Chance-constrained model predictive control. **AIChE Journal**, Wiley Online Library, v. 45, n. 8, p. 1743–1752, 1999b.
- SERNA, Alvaro; NORMEY-RICO, Julio E.; TADEO, Fernando. Model predictive control of hydrogen production by renewable energy. **IREC 2015**, 2015.
- SHAYEGHI, Hossein; SHAHRYARI, Elnaz; MORADZADEH, Mohammad; SIANO, Pierluigi. A Survey on Microgrid Energy Management Considering Flexible Energy Sources. **Energies**, Multidisciplinary Digital Publishing Institute, v. 12, n. 11, p. 2156, 2019.



- SHOULTS, Raymond R; CHANG, Show Kang; HELMICK, Steve; GRADY, W Mack. A practical approach to unit commitment, economic dispatch and savings allocation for multiple-area pool operation with import/export constraints. **IEEE Transactions on Power Apparatus and Systems**, IEEE, n. 2, p. 625–635, 1980.
- SONG, Nah-Oak; LEE, Ji-Hye; KIM, Hak-Man; IM, Yong Hoon; LEE, Jae Yong. Optimal energy management of multi-microgrids with sequentially coordinated operations. **Energies**, Multidisciplinary Digital Publishing Institute, v. 8, n. 8, p. 8371–8390, 2015.
- SOUZA, Glauce De; ODLOAK, Darci; ZANIN, Antônio C. Real time optimization (RTO) with model predictive control (MPC). **Computers & Chemical Engineering**, v. 34, n. 12, p. 1999–2006, 2010.
- SU, Wencong; WANG, Jianhui; ROH, Jaehyung. Stochastic Energy Scheduling in Microgrids With Intermittent Renewable Energy Resources. **IEEE transactions on smart grid**, p. 1949–3053, 2013.
- SU, Wencong; WANG, Jianhui; ROH, Jaehyung. Stochastic energy scheduling in microgrids with intermittent renewable energy resources. **IEEE Transactions on Smart Grid**, IEEE, v. 5, n. 4, p. 1876–1883, 2014.
- TAVAKOLI, Mehdi; SHOKRIDEHAKI, Fatemeh; MARZBAND, Mousa; GODINA, Radu; POURESMAEIL, Edris. A two stage hierarchical control approach for the optimal energy management in commercial building microgrids based on local wind power and PEVs. **Sustainable Cities and Society**, Elsevier, v. 41, p. 332–340, 2018.
- TOH, Kim-Chuan; TODD, Michael J; TÜTÜNCÜ, Reha H. SDPT3-a Matlab software package for semidefinite programming, version 1.3. **Optimization methods and software**, Taylor & Francis, v. 11, n. 1-4, p. 545–581, 1999.
- UMMELS, Bart C; GIBESCU, Madeleine; PELGRUM, Engbert; KLING, Wil L; BRAND, Arno J. Impacts of wind power on thermal generation unit commitment and dispatch. **IEEE Transactions on energy conversion**, IEEE, v. 22, n. 1, p. 44–51, 2007.
- VACCARI, Marco; PANNOCCHIA, Gabriele. A Modifier-Adaptation Strategy towards Offset-Free Economic MPC. **Process**, 2017.
- VACCARI, Marco; PANNOCCHIA, Gabriele. Implementation of an economic MPC with robustly optimal steady-state behavior. In: IFAC PapersOnLine. [S.l.: s.n.], 2018.

- VALVERDE, L.; ROSA, F.; REAL, A.J. del; ARCE, A.; BORDONS, C. Modeling, simulation and experimental set-up of a renewable hydrogen-based domestic microgrid. **International Journal of Hydrogen Energy**, Elsevier, v. 38, p. 11672–11684, 2012.
- VELARDE, P.; MAESTRE, J.M.; OCAMPO-MARTINEZ, C.; BORDONS, C. Application of Robust Model Predictive Control to a Renewable Hydrogen-based Microgrid. In: EUROPEAN Control Conference. [S.l.: s.n.], 2016.
- VELARDE, P.; VALVERDE, L.; MAESTRE, J.M.; OCAMPO-MARTINEZ, C.; BORDONS, C. On the comparison of stochastic model predictive control strategies applied to a hydrogen-based microgrid. **Journal of Power Sources**, v. 343, p. 161–173, 2017. DOI: <http://dx.doi.org/10.1016/j.jpowsour.2017.01.015>.
- W. GAO; S. ENGELL. Iterative set-point optimization of batch chromatography. **Computers & Chemical Engineering**, n. 29, p. 1401–1409, 2005.
- WANG, Qianfan; GUAN, Yongpei; WANG, Jianhui. A Chance-Constrained Two-Stage Stochastic Program for Unit Commitment With Uncertain Wind Power Output. **IEEE TRANSACTIONS ON POWER SYSTEMS**, v. 27, n. 1, p. 0885–8950, fev. 2012.
- WANG, Ran; WANG, Ping; XIAO, Gaoxi; GONG, Shimin. Power demand and supply management in microgrids with uncertainties of renewable energies. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 63, p. 260–269, 2014.
- WÜRTH, Lynn; RAWLINGS, James B.; MARQUARDT, Wolfgang. Economic Dynamic Real-Time Optimization and Nonlinear Model-Predictive Control on Infinite Horizons. **IFAC Proceedings Volumes**, v. 42, n. 11, p. 219–224, 2009. 7th IFAC Symposium on Advanced Control of Chemical Processes. DOI: <http://dx.doi.org/10.3182/20090712-4-TR-2008.00033>.
- XIAO, Jianfang; WANG, Peng; SETYAWAN, Leonardy. Hierarchical control of hybrid energy storage system in DC microgrids. **IEEE Transactions on Industrial Electronics**, IEEE, v. 62, n. 8, p. 4915–4924, 2015.
- XU, Xiandong; JIA, Hongjie; WANG, Dan; DAVID, C Yu; CHIANG, Hsiao-Dong. Hierarchical energy management system for multi-source multi-product microgrids. **Renewable Energy**, Elsevier, v. 78, p. 621–630, 2015.

- YAFFEE, R.A.; MCGEE, M. **An Introduction to Time Series Analysis and Forecasting: With Applications of SAS<sup>®</sup> and SPSS<sup>®</sup>**. [S.l.]: Elsevier Science, 2000.
- YAN, Jun; BITMEAD, Robert R. Incorporating state estimation into model predictive control and its application to network traffic control. **Automatica**, v. 41, n. 4, p. 595–604, 2005.
- YING, Chao-Ming; JOSEPH, Babu. Performance and Stability Analysis of LP-MPC and QP-MPC Cascade Control Systems. **Alche Hournal**, v. 45, n. 7, p. 1521–1534, 1999.
- YO, Masaki; ONO, Masahiro; ADACHI, Shuichi; MURAYAMA, Dai; OKITA, Nobuo. Power Output Smoothing for Hybrid Wind-Solar Thermal Plant using Chance-constrained Model Predictive Control. In: 53RD IEEE Conference on Decision and Control. [S.l.: s.n.], 2014.
- YU, Zhe; JIA, Liyan; MURPHY-HOYE, Mary C; PRATT, Annabelle; TONG, Lang. Modeling and stochastic control for home energy management. **IEEE Transactions on Smart Grid**, IEEE, v. 4, n. 4, p. 2244–2255, 2013.
- ZANIN, A.C.; GOUVÊA, M. Tvrzsk de; ODLOAK, D. Integrating real-time optimization into the model predictive controller of the FCC system. **Control Engineering Practice**, v. 10, n. 8, p. 819–831, 2002.
- ZHANG, Bingying; LI, Qiqiang; WANG, Luhao; FENG, Wei. Robust optimization for energy transactions in multi-microgrids under uncertainty. **Applied Energy**, Elsevier, v. 217, p. 346–360, 2018.
- ZHANG, G Peter. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, Elsevier, v. 50, p. 159–175, 2003.

## ANEXO A – TRANSFORMAÇÃO LINEAR DE UMA VARIÁVEL ALEATÓRIA MULTIVARIÁVEL

Seja  $\mathbf{q}$  uma variável aleatória gaussiana multivariável  $\mathbf{q} \sim \mathcal{N}(\bar{\mathbf{q}}, \mathbf{C}_q)$ , com vetor de médias  $\bar{\mathbf{q}}$  e matriz de covariância  $\mathbf{C}_q$ . Uma transformação linear

$$\mathbf{r} = \mathbf{A}\mathbf{q} + \mathbf{b} \quad (180)$$

com  $\mathbf{A}$  uma matriz ( $n \times m$ ) e  $\mathbf{b}$  um vetor ( $n \times 1$ ) pode ser obtida valendo-se do fato de que a esperança matemática  $\mathbf{E}[\cdot]$  é um operador linear (PINHEIRO *et al.*, 2012).

Cálculo da média resultante  $\bar{\mathbf{r}}$ :

$$\begin{aligned} \bar{\mathbf{r}} &= \mathbf{E}[\mathbf{r}] = \mathbf{E}[\mathbf{A}\mathbf{q} + \mathbf{b}] \\ &= \mathbf{A}\mathbf{E}[\mathbf{q}] + \mathbf{b} \end{aligned}$$

resultando em

$$\bar{\mathbf{r}} = \mathbf{A}\bar{\mathbf{q}} + \mathbf{b} \quad (181)$$

Cálculo da covariância resultante  $\mathbf{C}_r$ :

$$\begin{aligned} \mathbf{C}_r &= \mathbf{E}[(\mathbf{q} - \bar{\mathbf{q}})(\mathbf{q} - \bar{\mathbf{q}})'] \\ &= \mathbf{E}[(\mathbf{A}\mathbf{q} + \mathbf{b} - \mathbf{A}\bar{\mathbf{q}} - \mathbf{b})(\mathbf{A}\mathbf{q} + \mathbf{b} - \mathbf{A}\bar{\mathbf{q}} - \mathbf{b})'] \\ &= \mathbf{E}[(\mathbf{A}(\mathbf{q} - \bar{\mathbf{q}}))(\mathbf{A}(\mathbf{q} - \bar{\mathbf{q}}))'] \\ &= \mathbf{E}[\mathbf{A}(\mathbf{q} - \bar{\mathbf{q}})(\mathbf{q} - \bar{\mathbf{q}})' \mathbf{A}'] \\ &= \mathbf{A}\mathbf{E}[(\mathbf{q} - \bar{\mathbf{q}})(\mathbf{q} - \bar{\mathbf{q}})'] \mathbf{A}' \end{aligned}$$

resultando em

$$\mathbf{C}_r = \mathbf{A}\mathbf{C}_q\mathbf{A}' \quad (182)$$

Conclue-se, portanto, que a transformação linear (180) da variável  $\mathbf{q}$  resulta em uma outra variável aleatória gaussiana

$$\mathbf{r} \sim \mathcal{N}(\mathbf{A}\bar{\mathbf{q}} + \mathbf{b}, \mathbf{A}\mathbf{C}_q\mathbf{A}') \quad (183)$$

## ANEXO B – MODELAGEM DO SISTEMA DE QUATRO TANQUES

O sistema consiste em quatro tanques, dois superiores e dois inferiores, além de um reservatório localizado sob esses tanques. Os tanques superiores têm escoamento livre através de um orifício para os tanques inferiores, como pode ser visto na Figura 78. A água é succionada do reservatório através de duas bombas centrífugas e, por meio de duas válvulas de três vias, a água é direcionada para cada um dos tanques. O sistema é descrito pelas seguintes equações diferenciais

$$\begin{aligned}
 A \frac{dh_1}{dt} &= -a_1 \sqrt{2gh_1} + a_3 \sqrt{2gh_3} + \frac{\gamma_a q_a}{3600} \\
 A \frac{dh_2}{dt} &= -a_2 \sqrt{2gh_2} + a_4 \sqrt{2gh_4} + \frac{\gamma_b q_b}{3600} \\
 A \frac{dh_3}{dt} &= -a_3 \sqrt{2gh_3} + (1 - \gamma_b) \frac{q_b}{3600} \\
 A \frac{dh_4}{dt} &= -a_4 \sqrt{2gh_4} + (1 - \gamma_a) \frac{q_a}{3600}
 \end{aligned} \tag{184}$$

sendo  $h_n$  com  $n = [1, 4]$  a altura de cada tanque. Os demais parâmetros estão relacionados na Tabela 15.

O sistema foi linearizado no ponto  $(h_0, u_0)$  utilizando o seguinte modelo no espaço de

Tabela 15 – Parâmetros do processo

Símbolo	Descrição	Valor
$A$	Área da seção transversal do tanque	0.03 m <sup>2</sup>
$a_1$	Constante de descarga do tanque 1	1.310 10 <sup>-4</sup> m <sup>2</sup>
$a_2$	Constante de descarga do tanque 2	1.507 10 <sup>-4</sup> m <sup>2</sup>
$a_3$	Constante de descarga do tanque 3	9.267 10 <sup>-4</sup> m <sup>2</sup>
$a_4$	Constante de descarga do tanque 4	8.816 10 <sup>-4</sup> m <sup>2</sup>
$h_{max1}$	Limite superior do tanque 1	1.36 m
$h_{max2}$	Limite superior do tanque 2	1.36 m
$h_{max3}$	Limite superior do tanque 3	1.30 m
$h_{max4}$	Limite superior do tanque 4	1.30 m
$h_{min1}$	Limite inferior do tanque 1	0.20 m
$h_{min2}$	Limite inferior do tanque 2	0.20 m
$h_{min3}$	Limite inferior do tanque 3	0.20 m
$h_{min4}$	Limite inferior do tanque 4	0.20 m
$q_{max_a}$	Vazão máxima da bomba a	3.6 m <sup>3</sup> /h
$q_{max_b}$	Vazão máxima da bomba b	4.0 m <sup>3</sup> /h
$q_{min_a}$	Vazão mínima da bomba a	0 m <sup>3</sup> /h
$q_{min_b}$	Vazão mínima da bomba b	0 m <sup>3</sup> /h
$g$	Aceleração da gravidade	9.81 m <sup>2</sup> /s
$\gamma_a$	Parâmetro da válvula de três vias	0.3
$\gamma_b$	Parâmetro da válvula de três vias	0.4
$h_1^0$	Ponto de equilíbrio do tanque 1	0.6537 m
$h_2^0$	Ponto de equilíbrio do tanque 2	0.6524 m
$h_3^0$	Ponto de equilíbrio do tanque 3	0.6594 m
$h_4^0$	Ponto de equilíbrio do tanque 4	0.6587 m
$q_a^0$	Ponto de equilíbrio da bomba a	m <sup>3</sup> /h
$q_b^0$	Ponto de equilíbrio da bomba b	m <sup>3</sup> /h




Figura 78 – Sistema de 4 tanques.

estados

$$\frac{dx}{dt} = \begin{bmatrix} \frac{-1}{\tau_1} & 0 & \frac{A_3}{A_1\tau_3} & 0 \\ 0 & \frac{-1}{\tau_2} & 0 & \frac{A_4}{A_2\tau_4} \\ 0 & 0 & \frac{-1}{\tau_3} & 0 \\ 0 & 0 & 0 & \frac{-1}{\tau_4} \end{bmatrix} x + \begin{bmatrix} \frac{\gamma_a}{A_1} & 0 \\ 0 & \frac{\gamma_b}{A_2} \\ 0 & \frac{(1-\gamma_b)}{A_3} \\ \frac{(1-\gamma_a)}{A_4} & 0 \end{bmatrix} u \quad (185)$$

$$y = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} x$$

sendo  $\tau_i = \frac{A_i}{a_i} \sqrt{\frac{2h_i^0}{g}} \geq 0, i = 1, \dots, 4$  as constantes de tempo de cada tanque. Este modelo foi discretizado usando um segurador de ordem zero com tempo de amostragem de 15 segundos,

resultando no seguinte modelo no españo de estados discretizado

$$\begin{aligned}x_{k+1} &= \begin{bmatrix} 0.9142 & 0 & 0.0585 & 0 \\ 0 & 0.9019 & 0 & 0.0554 \\ 0 & 0 & 0.9388 & 0 \\ 0 & 0 & 0 & 0.9416 \end{bmatrix} x_k + \begin{bmatrix} 0.0199 & 0.0013 \\ 0.0014 & 0.0264 \\ 0 & 0.0404 \\ 0.0472 & 0 \end{bmatrix} u_k \\ y_k &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} x_k\end{aligned}\tag{186}$$