

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JOÃO GUSTAVO COELHO PENA

**ESTRATÉGIA BASEADA EM HORIZONTE ROLANTE PARA
OTIMIZAÇÃO DA DISTRIBUIÇÃO DE GASES SIDERÚRGICOS
COM INCERTEZAS**

VITÓRIA-ES
2019

JOÃO GUSTAVO COELHO PENA

**ESTRATÉGIA BASEADA EM HORIZONTE ROLANTE PARA
OTIMIZAÇÃO DA DISTRIBUIÇÃO DE GASES SIDERÚRGICOS
COM INCERTEZAS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Doutor em Engenharia Elétrica, na área de concentração Sistemas de Controle.

Orientador: Prof. Dr. Helder Roberto de Oliveira Rocha.

VITÓRIA-ES
2019

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

P397e Pena, João Gustavo Coelho, 1983-
Estratégia baseada em horizonte rolante para otimização da distribuição de gases siderúrgicos com incertezas / João Gustavo Coelho Pena. - 2019.
91 f.

Orientador: Helder Roberto de Oliveira Rocha.
Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Controle preditivo. 2. Otimização matemática. 3. Gasômetro. 4. Siderurgia. 5. Análise de séries temporais. 6. Energia elétrica e calor - Cogeração. I. Rocha, Helder Roberto de Oliveira. II. Universidade Federal do Espírito Santo. Centro Tecnológico. III. Título.

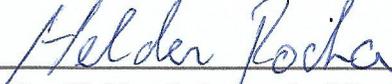
CDU: 621.3

**ESTRATÉGIA BASEADA EM HORIZONTE ROLANTE PARA
OTIMIZAÇÃO DA DISTRIBUIÇÃO DE GASES SIDERÚRGICOS
COM INCERTEZAS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Doutor em Engenharia Elétrica, na área de concentração Sistemas de Controle.

Aprovada em 17 de julho de 2019.

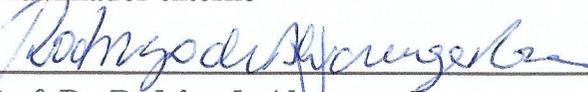
COMISSÃO EXAMINADORA



Prof. Dr. Helder Roberto de Oliveira Rocha
Universidade Federal do Espírito Santo
Orientador



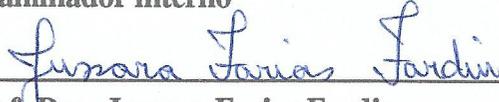
Prof. Dr. Edilson Fernandes de Arruda
Universidade Federal do Rio de Janeiro
Examinador externo



Prof. Dr. Rodrigo de Alvarenga Rosa
Universidade Federal do Espírito Santo
Examinador externo



Prof. Dr. Marcelo Vieira Segatto
Universidade Federal do Espírito Santo
Examinador interno



Prof. Dra. Jussara Farias Fardin
Universidade Federal do Espírito Santo
Examinador interno

*Aos meus pais, José Francisco e Maria Vitória, por cada gesto de amor, por cada palavra de motivação, por cada exemplo de encorajamento, por cada lição de fé.
À minha esposa, pela compreensão e estímulo.*

Agradecimentos

Agradeço ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo pela oportunidade de aprimoramento de minha formação profissional, em especial, por favorecer a realização de um sonho. Agradeço à CAPES (Coordenação de Aperfeiçoamento Pessoal de Nível Superior), pela bolsa concedida, sem a qual não teria sido possível minha dedicação ao presente trabalho.

Agradeço à ArcelorMittal pela oportunidade de poder realizar esta pesquisa. Certamente, o sucesso desta pesquisa seria incerto caso não fosse possível ter acesso às dependências da empresa e ao seu corpo técnico.

Agradeço aos professores e funcionários do Departamento de Engenharia Elétrica, principalmente pela amizade e atenção.

Agradeço ao professor Helder Roberto de Oliveira Rocha pela confiança, pela atenção e prontidão no auxílio para êxito deste projeto.

Sou grato, especialmente, ao professor José Leandro Félix Salles pelo zelo, dedicação e parceria no desenvolvimento desta pesquisa e realização desta tese. Essa conquista foi possível por conta do seu entusiasmo, seu cuidado e esforço, pela paciência, pelo apoio técnico e psicológico. Aprendi a admirá-lo sob diversas perspectivas, e sou grato por tudo isso.

Sou grato também aos engenheiros Valter Barbosa de Oliveira Júnior e Murilo Siqueira Muniz Teixeira da Silva, que deram amplo suporte à modelagem de processos, análises, simulações e testes dos modelos de previsão e otimização.

Sou grato à minha esposa, aos meus pais e irmãs pelo carinho, pelo auxílio e pelo entusiasmo.

Sou grato ao SENHOR Adonai Eloheinu, O Santo Deus de Avraham, e Yitz'chak, e Yisra'el. Sou grato por Suas bênçãos, pela graça e favorecimento em minha vida.

"Combati o bom combate, terminei a corrida, mantive a fé."

II Timóteo 4:7

Resumo

O processo de fabricação de ferro e aço é uma das atividades industriais que mais consomem energia e emitem poluentes atmosféricos. Por outro lado, a maioria desses gases pode ser usada como combustível para cogeração de eletricidade e vapor de processo; nesse caso, a utilização eficiente desses gases é primordial para economia de energia e redução de emissão de CO_2 . No entanto, a gestão deste sistema é uma atividade complexa, principalmente devido aos desequilíbrios entre os perfis de produção e consumo dos gases, às limitações de capacidade dos gasômetros e suas restrições operacionais, bem como às restrições para o uso de energia em usinas termoelétricas. Como resultado, o excesso temporário de gases siderúrgicos, ao longo do tempo, poderia levar o gasômetro a ultrapassar sua capacidade, e então forçar a queima de gás nas torres de proteção, resultando em perdas econômicas e poluição ambiental. Por outro lado, a escassez de gás siderúrgico produz problemas mecânicos no gasômetro e afeta o processo produtivo. Assim, é de grande importância otimizar a programação e distribuição do sistema de gases siderúrgicos para reduzir a queima ou escassez de gás e para manter a estabilidade do sistema de distribuição de gases.

Esta tese aborda o uso de um algoritmo de controle por horizonte rolante na resolução, em tempo real, do problema de planejamento de curto prazo dos gases siderúrgicos numa usina siderúrgica integrada, considerando incertezas nas vazões dos gases. Modelos adaptativos de séries temporais, determinados a partir de dados reais, realizam previsões para cada produtor e consumidor de gás nas principais unidades da usina siderúrgica. Os consumos individuais de gás de alto-forno e de gás de coqueria são modelados usando o método sazonal de Holt-Winters com constantes de suavização estimadas via algoritmo genético, enquanto as produções individuais de gás de alto-forno e de gás de coqueria são modeladas a partir da média móvel auto-regressiva e integrada. A produção de gás LDG é prevista usando um método heurístico que leva em conta informações operacionais. Os parâmetros do modelo são atualizados periodicamente devido às não-linearidades presentes nas séries temporais. Após a fase de previsão, o algoritmo executa decisões de curto prazo usando um modelo de otimização MILP, que minimiza o desequilíbrio dinâmico provocado pelas incertezas das flutuações da produção e consumo de gás, e maximiza o aproveitamento energético. Por meio de simulações computacionais, será evidenciado que a estabilidade operacional dos gasômetros e da produção de energia elétrica aumenta, enquanto o desperdício de gases nas torres de queima diminui quando o horizonte de controle do algoritmo do horizonte rolante é reduzido. A otimização por enxame de partículas foi aplicada para sintonizar as penalidades do modelo MILP de otimização, de modo a melhorar os indicadores de desempenho do sistema de distribuição de gases.

Palavras Chave: Algoritmo de horizonte rolante, Controle do nível dos gasômetros, Distribuição de Combustíveis Siderúrgicos, Economia de energia, Método de Suavização Exponencial de Holt-Winters, Modelo Auto-Regressivo Integrado de Média Móvel, Planejamento de Curto Prazo, Otimização por Enxame de Partículas, Previsão de gases siderúrgicos, Programação Linear Inteira Mista.

Abstract

Manufacturing iron-and steel is one of the most energy intensive and pollutant industrial activities. On the other hand, the majority of these pollutant gases can be used as fuel for cogeneration of electricity and process steam; in that case, then the efficient utilisation of these gases is significant for energy saving and CO_2 reduction. However, the management of this system is a complex activity, mainly because of the imbalances between the production and consumption profiles of the gases, the capacity limitations of the gas accumulators and their operational restrictions, as well as the restrictions for the use of energy in the thermoelectric power plants. As a result, when a temporary excess of byproduct gases occurs over a timescale, the byproduct gasholder exceeds capacity, and this leads to byproduct gas flaring, which indicates an economic loss and pollution of the environment. However, a shortage of byproduct gas causes mechanical trouble to the byproduct gasholder and affects the production process. Thus, it is of great importance to optimise the scheduling and distribution of byproduct gases to reduce byproduct gas flaring or shortage, and to maintain the stability of the byproduct gases distribution system.

This thesis addresses the real-time by-product gas scheduling in an integrated iron-and steel-making industry with uncertainty in by-product gas flows by means of a rolling horizon algorithm. Adaptive time-series models determined from real data perform forecast for each producer and consumer of by-product gases in main units of the steel-making plant. The individual consumptions of the blast furnace and coke oven gases are modelled using the seasonal Holt-Winters method with smoothing constants estimated via genetic algorithm, whereas the individual productions of the blast furnace and coke oven are identified from autoregressive and integrated moving-average. LDG gas production is forecasted using a heuristic method that leverages the operational information. The model's parameters are updated periodically due to the nonlinearities present in the time series. After the forecasting phase, the algorithm performs short-term decisions using a MILP optimization model, that minimizes the imbalance between the random dynamics of the by-product fuel generation and consumption and maximizes the energy efficiency. Computational simulations suggest that the operational stability of the gas holders and the electrical energy production increase, whereas the waste of gases in flare stack decreases, when the control horizon of the rolling horizon algorithm is reduced. Particle swarm optimization was applied to identify reasonable penalty factors which were used in the MILP model to obtain reasonable optimisation of the byproduct gas system.

Keywords: By-product gas forecasting, By-product gas distribution, Energy saving, Gas holder level control, Mixed Integer Linear Programming, Particle Swarm Optimization, Rolling horizon algorithm, Scheduling, Seasonal exponential smoothing method, ARIMA.

Lista de Figuras

1	Diagrama simplificado da distribuição de gases siderúrgicos.	p. 2
2	Limites operacionais de nível dos gasômetros.	p. 4
3	Hierarquia de Controle de Processos.	p. 21
4	Fluxograma do algoritmo de ramificação e avaliação progressiva.	p. 27
5	Trechos originais das séries de produção de BFG e COG.	p. 35
6	Trechos originais das séries de produção de LDG.	p. 36
7	Trechos originais das séries de consumo de BFG nos altos-fornos e coqueria.	p. 37
8	Trechos originais das séries de consumo de COG nos altos-fornos e coqueria.	p. 37
9	Trechos originais das séries de demanda de gases e vapor de processo.	p. 38
10	Trecho original da série de demanda de eletricidade.	p. 38
11	Rede de distribuição de BFG.	p. 41
12	Rede de distribuição de COG.	p. 41
13	Rede de distribuição de LDG.	p. 42
14	Série temporal Real (linha azul) e Prevista (linha vermelha) pelo modelo Holt-Winters.	p. 45
15	Série temporal Real (linha azul) e Prevista (linha vermelha) pelo modelo ARIMA.	p. 48
16	Perfil da recuperação do gás LDG produzido.	p. 49
17	Série temporal Real (linha azul) e Prevista (linha vermelha) do total de LDG útil produzido.	p. 51
18	Nível dos gasômetros segundo estratégias RHE1, RHE5 e RHPF1.	p. 57
19	Comparação da função de avaliação da melhor partícula de cada modelo PSO simulado.	p. 62
20	Espaço investigado pelo modelo PSO_4	p. 63
21	Desempenho da função de avaliação das oito melhores partículas do PSO_4	p. 63
22	Ajuste dos pesos dos gasômetros via PSO_4	p. 65
23	Ajuste dos pesos dos queimadores via PSO_4	p. 66

Lista de Tabelas

1	Comparação entre as mais relevantes propostas de otimização da distribuição de combustíveis siderúrgicos.	p. 11
2	Modelo das séries temporais usadas no algoritmo proposto.	p. 39
3	Tempo Médio de Processamento(s) dos métodos de previsão HW, ARIMA e Heurístico em segundos.	p. 40
4	Tempo Médio de Processamento(s) dos métodos de previsão ARIMA e Média Móvel em segundos.	p. 40
5	Tempo médio para execução dos modelos de previsão em segundos. . .	p. 40
6	Distribuição dos consumidores não-controlados de BFG e COG.	p. 42
7	Validação da previsão das séries temporais de consumo não-controlado dos gases BFG e COG (BF = Alto-Forno, CO = Coqueria).	p. 45
8	Validação da previsão das séries temporais de produção dos gases BFG e COG (BF = Alto-Forno, CO = Coqueria).	p. 47
9	Probabilidade dos eventos E1 U E2 e E3.	p. 50
10	\overline{MAPE} da previsão da extração de vapor de processo, do consumo de LDG na calcinação e de BFG no PCI.	p. 51
11	Informações gerais sobre os queimadores.	p. 53
12	Características Operacionais das caldeiras e turbinas.	p. 53
13	Poder calorífico.	p. 54
14	Limites máximos para operação das estações de mistura.	p. 54
15	Custos operacionais aplicados à Expressão (2.2).	p. 55
16	Custos aplicados à Expressão (2.3).	p. 55
17	Limites Operacionais dos Gasômetros (dam^3).	p. 58
18	Queima de gás nas torres de proteção e escassez nos gasômetros.	p. 58
19	Vazões médias do consumo de combustíveis gasosos nas termoelétricas (PP) e nas estações de mistura (MS).	p. 59
20	Impacto dos modelos de previsão de média móvel na geração elétrica. . .	p. 61
21	Simulações PSO realizadas.	p. 61
22	Parâmetros da melhor partícula do PSO_4	p. 64

Nomenclatura

Abreviaturas e índices	
BFG	Gás de alto-forno
COG	Gás de coqueria
LDG	Gás de aciaria
MG	Gás misto
NG	Gás natural
TAR	Alcatrão
MILP	Programação Linear Inteira Mista
PS	Vapor de processo
BF	Alto-Forno
CO	Coqueria
CV	Convertedor
HSM	Laminador de tiras a quente
PCI	Unidade de injeção de carvão pulverizado
MA	Modelo de média móvel
ARMA	Modelo auto-regressivo de média móvel
ARIMA	Modelo auto-regressivo integrado de média móvel
SARIMA	Modelo sazonal auto-regressivo integrado de média móvel
AG	Algoritmo genético
HW	Holt-Winters
$MAPE(t)$	Erro percentual absoluto médio no período t
\overline{MAPE}	Média do índice $MAPE(t)$
MAE	Erro absoluto médio
MSE	Erro médio quadrático
$RMSE$	Raiz do erro médio quadrático
ABS	Indicador de desempenho relacionado ao número de comutações de queimadores
AEP	Indicador de desempenho relacionado à geração elétrica
$DGHL$	Indicador de desempenho relacionado ao gasômetro
$ELFS$	Indicador de desempenho relacionado às perdas nas torres
$UTAR$	Indicador de desempenho relacionado ao uso de TAR nas termoelétricas
ABS_N	Indicador de desempenho ABS normalizado entre 0 e 1
AEP_N	Indicador de desempenho AEP normalizado entre 0 e 1
$DGHL_N$	Indicador de desempenho $DGHL$ normalizado entre 0 e 1
$ELFS_N$	Indicador de desempenho $ELFS$ normalizado entre 0 e 1
$UTAR_N$	Indicador de desempenho $UTAR$ normalizado entre 0 e 1
$RHPP1$	Algoritmo de horizonte rolante com previsão perfeita e $h_c = 1$
$RHPP5$	Algoritmo de horizonte rolante com previsão perfeita e $h_c = 5$
$RHE1$	Algoritmo de horizonte rolante com incerteza na previsão e $h_c = 1$
$RHE5$	Algoritmo de horizonte rolante com incerteza na previsão e $h_c = 5$

Abreviaturas e índices

TBFGc	Consumo total de BFG não-controlado
TCOGc	Consumo total de COG não-controlado
TBFGp	Produção total de BFG
TCOGp	Produção total de COG
$TLDG^{uv}$	Volume útil total de LDG produzido
$iter$	Iteração corrente
$J(t)$	Função objetivo do problema MILP
J_{op}	Custos operacionais dos gasômetros no problema MILP
$J(t)$	Custos operacionais dos queimadores no problema MILP
F	Conjunto de combustíveis
G	Conjunto de gases
Mw_t	Janela móvel de dados históricos
fac	Função de autocorrelação
fcc	Função de correlação cruzada

Parâmetros

d	Número de diferenças para uma série não-estacionária se tornar estacionária
p, q	Ordem do polinômio auto-regressivo e de média móvel, respectivamente
h_f	Horizonte de previsão
h_c	Horizonte de controle
h_s	Horizonte de planejamento
t_0	Tempo inicial de planejamento
T_s	Tempo total de planejamento
T_f	Tempo total de previsão
t_{it}	Total de iterações
T	Intervalo de tempo do modelo de otimização MILP
ΔT	Intervalo de amostragem do sistema de aquisição de dados
s	Período sazonal de Z_t
α	Constante de suavização do nível
β	Constante de suavização da tendência
γ	Constante de suavização sazonal
Li_t	Intervalo entre o início do sopro de oxigênio e o começo da recuperação de LDG
Lf_t	Intervalo entre o fim de sopro de oxigênio e o fim da recuperação de LDG
$\bar{L}i$	Média do Li_t
$\bar{L}f$	Média do Lf_t
N_{bo}	Total de caldeiras
N_{bu}	Total de queimadores numa caldeira
N'_{bu}	Número máximo de comutações do queimador F numa caldeira
N_m	Total de estações de mistura
N_T	Total de turbinas
W_H^G	Penalidade pela operação do gasômetro G acima do limite máximo de segurança [$US\$/m^3$]
W_L^G	Penalidade pela operação do gasômetro G abaixo do limite inferior de segurança [$US\$/m^3$]
$W_{sw}^{F,i}$	Penalidade pela comutação simultânea de i queimadores F [$US\$/unit$]
W_M^i	Penalidade devido a produção em excesso de MG na estação de mistura i [$US\$/m^3$]
W_{d+}^G	Penalidade para qualquer desvio acima do nível x_N^G do gasômetro G [$US\$/m^3$]
W_{d-}^G	Penalidade para qualquer desvio abaixo do nível x_N^G do gasômetro G [$US\$/m^3$]

Parâmetros

C^F	Custo do combustível F [$US\$/m^3$ ou $US\$/kg$]
C^{Elec}	Preço da eletricidade [$US\$/kWh$]
C^{PS}	Preço do vapor de processo [$US\$/kg$]
U_j^F	Capacidade máxima do queimador j do combustível F [m^3/h]
$C_{op,r}^F$	Faixa operacional dos queimadores [%]
H_j^{stm}	Entalpia do vapor de processo na entrada da turbina j [kJ/kg]
H_j^{water}	Entalpia da água na entrada da caldeira j [kJ/kg]
H_j^{ext}	Entalpia do vapor de processo na extração da turbina j [kJ/kg]
H_j^{exh}	Entalpia do vapor de processo na saída da turbina j [kJ/kg]
η_j^B	Rendimento da caldeira j
η_j^T	Rendimento da turbina j
η_j^{ext}	Eficiência da extração de vapor de processo da turbina j
Cv^F	Poder calorífico do combustível F [MJ/m^3]
Cv_j^G	Poder calorífico do gás G consumido na estação de mistura j [MJ/m^3]
$Cv_{min,j}^{MG}$	Poder calorífico inferior do gás misto produzido na estação de mistura j [MJ/m^3]
$Cv_{max,j}^{MG}$	Poder calorífico superior do gás misto produzido na estação de mistura j [MJ/m^3]
$f_{min,j}^{b,F}$	Vazão mínima do combustível F consumido na fornalha de cada caldeira [m^3/h]
$f_{max,j}^{b,F}$	Vazão máxima do combustível F consumido na fornalha de cada caldeira [m^3/h]
$f_{min,j}^{stm}$	Limite inferior de geração de vapor de processo na caldeira j [kg/h]
$f_{max,j,t}^{stm}$	Limite superior de geração de vapor de processo na caldeira j [kg/h]
$f_{min,j}^{tb}$	Mínima vazão de vapor admitida pela turbina j [kg/h]
$f_{max,j}^{tb}$	Máxima vazão de vapor admitida pela turbina j [kg/h]
$fp_{min,j}^m$	Mínima vazão de gás misto produzido na estação de mistura j [m^3/h]
$fp_{max,j}^m$	Máxima vazão de gás misto produzido na estação de mistura j [m^3/h]
fp_{max}^{MG}	Máxima vazão para distribuição de gás misto no sistema [m^3/h]
$fc_{min,j}^{m,G}$	Mínima vazão de gás G consumida pela estação de mistura j [m^3/h]
$fc_{max,j}^{m,G}$	Máxima vazão de gás G consumida pela estação de mistura j [m^3/h]
ω	Coefficiente de inércia
ψ_1	Coefficiente de aceleração responsável por ajuste social
ψ_2	Coefficiente de aceleração responsável por ajuste cognitivo

Variáveis	
R_1	Variáveis aleatórias independentes com distribuição uniforme em [0,1]
R_2	Variáveis aleatórias independentes com distribuição uniforme em [0,1]
$v_i(t)$	Vetor velocidade da partícula i no instante t
x_{p_i}	É a i -ésima melhor componente de posição da partícula
x_{s_i}	É o i -ésimo componente da melhor posição alcançada dentre todas partículas
$\epsilon_t(k)$	Erro relativo à previsão k -passos-à frente de Z_t
a_t	Ruído branco com média zero
μ_t	Componente de nível Z_t
T_t	Componente de tendência Z_t
S_t	Componente de sazonalidade Z_t
$\bar{\mu}_t$	Estimativa da constante de nível por HW
\bar{T}_t	Estimativa da constante de tendência por HW
\bar{S}_t	Estimativa da constante de sazonalidade por HW
B	Operador de atraso
$\phi(B)$	Polinômio auto-regressivo de ordem p
$\theta(B)$	Polinômio de média móvel de ordem q
W_t	Série temporal estacionária
Z_t	Série temporal no instante de tempo t
$\hat{Z}_t(k)$	Previsão k -passos-à frente de Z_t
Ti_{o2}	Instante inicial do sopro de oxigênio
Tf_{o2}	Instante final do sopro de oxigênio
Ti_r	Instante inicial de recuperação de LDG
Tf_r	Instante final de recuperação de LDG
$\bar{T}i_r$	Tempo médio de início de recuperação de LDG
$\bar{T}f_r$	Tempo médio do fim de recuperação de LDG
$\hat{T}i_{o2}(k)$	Previsão k -passos-à frente para início do sopro de oxigênio
$\hat{T}f_{o2}(k)$	Previsão k -passos-à frente para fim do sopro de oxigênio
$\hat{T}i_r(k)$	Previsão k -passos-à frente para início da recuperação de LDG
$\hat{T}f_r(k)$	Previsão k -passos-à frente para fim da recuperação de LDG
Z_t^r	Volume de LDG recuperado no período t
Z_t^p	Volume de LDG produzido no período t
Z_t^{uv}	Volume de LDG útil produzido no período t
\bar{Z}_t^r	Volume médio de LDG recuperado no período t
\bar{Z}_t^{bfs}	Volume médio de LDG queimado no período t
$\bar{Z}_t^{uv}(k)$	Média do volume útil de LDG produzido no período t
$\hat{Z}_t^{uv}(k)$	Previsão k -passos-à frente da produção de LDG útil
Z_t^{bfs}	LDG queimado nas torres nas torres de proteção no período t
Z_t^{blc}	LDG com baixo poder calorífico queimado nas torres de proteção no período t
Ei	Evento $i = 1, 2, 3$

Variáveis	
Fp_t^G	Vazão total do total gás G produzido no período t [m^3]
Fc_t^G	Vazão total não-controlada de gás G consumido no período t [m^3]
x_t^G	Nível do gasômetro G [m^3]
x_{LL}^G	Quantidade mínima requerida de gás no gasômetro G [m^3]
x_L^G	Nível seguro mínimo de gás no gasômetro G [m^3]
x_N^G	Nível operacional de referência do gasômetro G [m^3]
x_H^G	Nível seguro máximo do gasômetro G [m^3]
x_{HH}^G	Quantidade máxima de gás no gasômetro G [m^3]
$fc_j^{b,F}$	Vazão do combustível F consumido na caldeira j no período t [m^3/h]
$fc_j^{m,G}$	Vazão do gás G consumido na estação de mistura j no período t [m^3/h]
$S_{H,t}^G$	Volume de gás G desperdiçado na torre de queima no período t [m^3]
$S_{M,t}^j$	Volume de MG para torre de queima da estação de mistura j no período t [m^3]
$S_{L,t}^G$	Volume mínimo a ser preservado no gasômetro G para manter estável a pressão de linha
$S_{d^+,t}^G$	Volume acima do nível de referência do gasômetro G
$S_{d^-,t}^G$	Volume abaixo do nível de referência do gasômetro G
Fp_t^G	Produção total de gás no período t [m^3/h]
Fc_t^G	Consumo total não-controlado de gás t [m^3/h]
D_t^{ps}	Demanda de vapor de processo no período t [kg]
D_t^E	Demanda de eletricidade no período t [kW]
$f_{j,t}^{water}$	Vazão de água para abastecimento da caldeira j no período t [m^3/h]
$f_{j,t}^{stm}$	Vazão de vapor produzido pela caldeira j no período t [m^3/h]
$f_{j,t}^{tb}$	Vazão de vapor na entrada da turbina j no período t [m^3/h]
$f_{j,t}^{psa}$	Vazão de vapor de processo extraído na saída da caldeira j no período t [m^3/h]
$f_{j,t}^{psb}$	Vazão de vapor de processo extraído da turbina j no período t [m^3/h]
$f_{j,t}^{ps}$	Vazão de vapor de processo extraído da termoelétrica j no período t [m^3/h]
$pw_{j,t}^{gen}$	Potência ativa gerada pelo turbogerador j no período t [MW]
$fc_{j,t}^{b,G}$	Quantidade de gás G consumido na caldeira j no período t [m^3]
$N_{i,t}^F$	Quantidade de queimadores F a ser acesa na caldeira i no período t
$\Delta N_{j,t}^F$	Total de acendimento/apagamento de queimadores F na caldeira i no período t
$sf_{j,t}^F$	Folga do queimador j no período t [m^3/h]
$ub_{j,t}^{F,i}$	Indica a decisão de ligar/desligar i queimadores de F na caldeira j no período t
$ibn_{j,t}^{F+,i}$	Indica quando i queimadores de F devem ser acesos na caldeira j no período t
$ibn_{j,t}^{F-,i}$	Indica quando i queimadores de F devem ser desligados na caldeira j no período t
$fp_{j,t}^m$	Vazão de gás misto produzido na estação de mistura j no período t [m^3/h]
fp_t^m	Vazão total de gás misto produzido nas estações de mistura no período t [m^3/h]
$fc_t^{m,hsm}$	Gás misto consumido no processo HSM no período t [m^3/h]
$fc_{j,t}^{m,b}$	Gás misto consumido na caldeira j no período t [m^3/h]
$fc_{j,t}^{m,G}$	É a vazão de gás G para estação de mistura j no período t [m^3/h]

Sumário

1	Introdução	p. 1
1.1	Sistema de distribuição de gases siderúrgicos	p. 2
1.1.1	O problema de otimização da distribuição de gases	p. 4
1.1.2	O estado da arte	p. 5
1.2	Originalidade da tese	p. 9
1.3	Justificativas	p. 15
1.4	Objetivos geral e específicos	p. 16
1.5	Organização da tese	p. 17
2	Otimização da distribuição de gases siderúrgicos em tempo real	p. 19
2.1	O algoritmo de horizonte de rolagem	p. 19
2.1.1	Restrições do Modelo MILP	p. 22
2.2	Implementação do Algoritmo de Otimização	p. 26
2.3	Sintonia dos parâmetros do Modelo MILP	p. 28
2.3.1	Conceitos básicos	p. 30
2.3.2	Descrição do algoritmo PSO	p. 30
2.3.3	Indicadores de desempenho	p. 32
3	Modelos de Previsão	p. 35
3.1	Definições gerais	p. 42
3.2	Modelo de Previsão Holt-Winters	p. 43
3.3	Modelo de Previsão ARIMA	p. 46
3.4	Modelo heurístico de previsão da produção de LDG	p. 48
3.5	Modelo de Média Móvel	p. 51
4	Simulações e resultados	p. 52
4.1	Simulações Computacionais	p. 52
4.1.1	Resultados do algoritmo de horizonte de rolagem	p. 55
4.2	Resultados da sintonia dos parâmetros do modelo MILP	p. 61
5	Conclusões	p. 67
5.1	Trabalhos futuros	p. 69
	Referências	p. 71

1 *Introdução*

O panorama atual sugere que o Consumo Global de Energia continua a aumentar (OECD/IEA, 2016). Em indústrias metalúrgicas, siderúrgicas, papel e celulose, cimento e separação de ar, a energia constitui um importante fator de custo. Neste sentido, é de grande interesse a redução deste custo, especialmente porque os custos energéticos estão subindo devido ao aumento da demanda de energia e mudanças no padrão de geração e distribuição (MERKERT et al., 2015).

Segundo Quader et al. (2015), a indústria siderúrgica é a segunda maior consumidora industrial de energia e é uma das atividades industriais que mais emite poluentes atmosféricos. Normalmente, as atividades desenvolvidas nos complexos siderúrgicos consomem cerca de 18% do consumo total de energia no mundo, segundo Zeng et al. (2018), e são responsáveis por aproximadamente 7% do total de emissões de CO_2 (JIN et al., 2017).

Todavia, se por um lado o consumo energético constitui em torno de 20% do custo operacional de uma usina siderúrgica, pelo menos 40% de todas as formas de energia consumida nas atividades siderúrgicas podem ser obtidas pelo aproveitamento de rejeitos gasosos dos processos siderúrgicos como combustíveis (ZHANG et al., 2011b), os quais podem ser usados inclusive na cogeração para produção de eletricidade e vapor de processo. Assim, segundo Merkert et al. (2015), uma maneira simples de diminuir os custos totais de energia, sem alteração no volume de produção, transita pelo aumento da eficiência energética que, no presente caso, pode ser obtido a partir do uso de gases siderúrgicos para cogeração de energia, (YANG et al., 2015). Por conta disso, é imprescindível que essas atividades sejam realizadas de modo bastante racional e planejado, buscando melhorar a eficiência energética e reduzir as emissões de CO_2 .

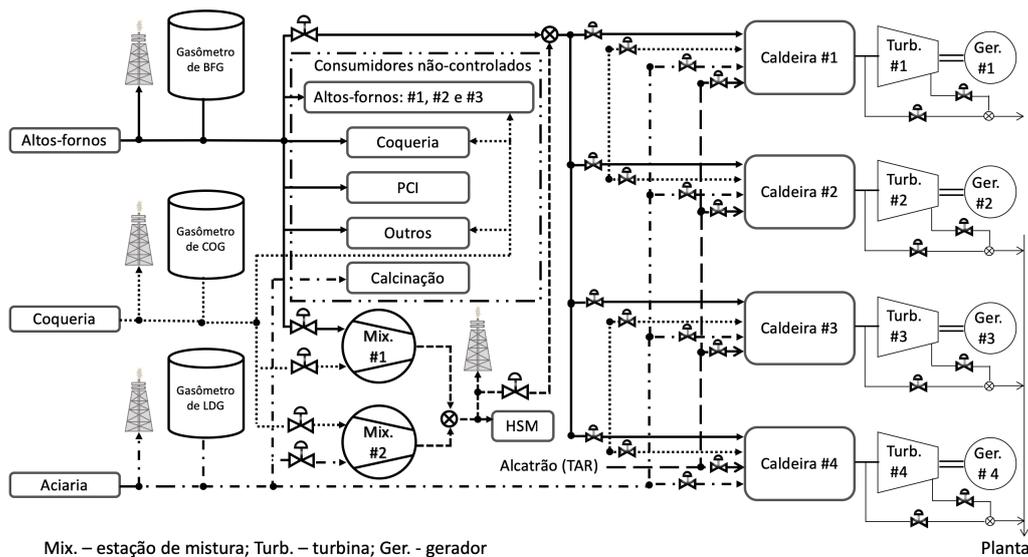
Uma usina siderúrgica integrada, onde são executadas todas as etapas necessárias para a transformação de minério de ferro em aço, envolve o uso de elevadas parcelas de energia e ao mesmo tempo gera uma quantidade abundante de gases residuais. Estes gases são elementos potencialmente poluentes, porém constituem um importante recurso energético secundário. Logo, o uso destes gases para cogeração de energia não somente melhora o uso de energia, como também diminui a poluição atmosférica. Esses combustíveis podem ser usados nas centrais termoelétricas para geração de vapor e força motriz. O vapor pode ser usado em diversas atividades como: secagem, evaporação, aquecimento, cozimento etc; enquanto que a força motriz é usada para transporte de materiais, bombeamento, acionamento de motores, compressores, bombas correias transportadoras e guindastes, dentre outras possibilidades.

1.1 Sistema de distribuição de gases siderúrgicos

Para o estudo proposto, os dados e as informações do sistema de distribuição de combustíveis siderúrgicos (equipamentos e processos) foram fornecidos pela ArcelorMittal Tubarão, siderúrgica situada no estado do Espírito Santo, Brasil. Isto é, os parâmetros e as restrições operacionais dos equipamentos e processos do problema de planejamento da distribuição de gases a curto prazo, assim como as séries de produção e consumo de gases siderúrgicos, de demanda de vapor de processo e eletricidade foram obtidos de uma planta industrial real.

A Figura 1 apresenta o diagrama simplificado da distribuição de gases siderúrgicos desta usina siderúrgica integrada, a qual será considerada nesta tese como indústria de referência para modelagem, simulação, estudos de caso e análise. Essa figura representa a planta modelada por Pena, Oliveira e Salles (2019), que é uma extensão do modelo de distribuição de gases formulado em Oliveira, Pena e Salles (2016), acrescido das estações de mistura e suas respectivas restrições.

Figura 1: Diagrama simplificado da distribuição de gases siderúrgicos.



Fonte: elaboração própria.

Observa-se na Figura 1 que nos altos-fornos é produzido o gás BFG (*Blast Furnace Gas*), na coqueria é produzido o gás COG (*Coke Oven Gas*) e o óleo alcatrão (*TAR*), e na aciaria é produzido o gás LDG (*Linz-Donawitz Gas*) durante o refino de ferro-gusa. Estes gases são importantes fontes de energia e podem ser usados individualmente ou misturados como combustíveis em diversos processos industriais na usina siderúrgica.

Neste complexo, os operadores do sistema de distribuição de gases siderúrgicos são responsáveis pelo controle do consumo de parte desses gases para cogeração de energia nas termoelétricas, e de parte na produção de gás misto destinado ao processo de Laminagem de Tiras a Quente, aqui denominado de *Hot-Strip-Mill* ou HSM. Porém, alguns consumidores são independentes e, portanto, o consumo não é controlado pelos operadores do sistema de distribuição de gases. Os principais consumidores não-controlados

são os altos-fornos que consomem BFG e COG, a coqueria que consome BFG e COG, a unidade de injeção de carvão pulverizado, mais conhecida como PCI (*Pulverized Coal Injection*) que consome BFG e a calcinação que consome LDG. Demais consumidores independentes, que representam menos de 1% do total de consumidores não-controlados de BFG e COG, como sinterização, calcinação e aciaria (aqui denominados como outros - Figura 1), não são considerados nesta tese.

Nas termoeletricas, os combustíveis são usados nos queimadores das fornalhas para gerar vapor d'água nas caldeiras, que é usado para movimentar turbinas cujos geradores elétricos estão acoplados. Uma pequena parte do vapor d'água, extraído das caldeiras e/ou turbinas, é direcionada para aquecimento de alguns processos industriais. Essa parcela é comumente chamada de vapor de processo. As fornalhas das caldeiras podem conter vários queimadores para o mesmo tipo de combustível.

No entanto, é importante salientar que os equipamentos dos processos siderúrgicos têm prioridade no atendimento das demandas de consumo dos gases *in natura* ou misto, assim como de vapor de processo (ZHAO et al., 2015). Portanto, somente o excedente de gás é usado para geração elétrica. Por essa razão, o consumo nas termoeletricas e uso nas misturadoras são controlados.

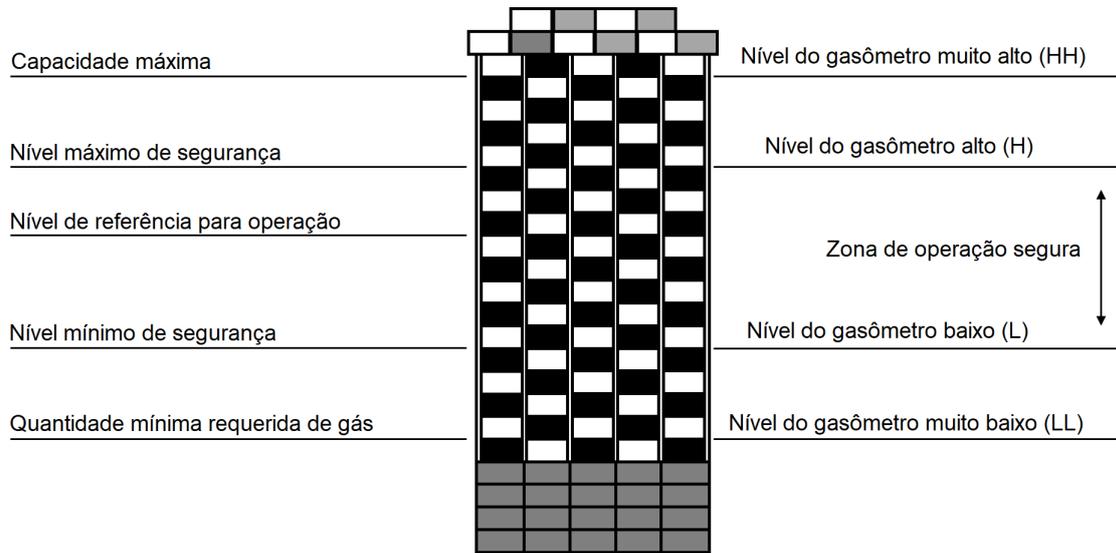
A partir das misturas dos gases BFG, COG e LDG, as estações de mistura de gases produzem o gás misto (*MG - Mixed Gas*) que é consumido principalmente no processo HSM. Quando a disponibilidade de um desses gases está eventualmente baixa, o gás natural (*NG - Natural Gas*) também pode ser usado nas estações de mistura. A principal função das estações de mistura é enriquecer o BFG com COG, ou enriquecer o LDG com COG ou NG, de modo a ter um gás resultante com características adequadas para consumo no HSM que é a área da usina que mais agrega valor ao produto final.

Num sistema de distribuição de gases siderúrgicos, um dos equipamentos mais importantes é o gasômetro. O gasômetro é um acumulador dinâmico de gás e tem como função principal manter a pressão de linha do sistema dentro de uma faixa operacional segura, o que corresponde a manter seu nível dentro dos limites operacionais de segurança, isto é, entre os níveis mínimo e máximo. Desta forma, os gasômetros são capazes de absorver a diferença entre o volume de gás produzido e o volume de gás consumido num intervalo de tempo, e de devolver essa quantidade durante certo intervalo de tempo quando a demanda for superior à quantidade produzida, e assim, mantém a estabilidade da pressão de linha do sistema de distribuição.

O gasômetro do gás $G = \text{BFG, COG ou LDG}$ opera num intervalo seguro se $x_L^G \leq x_t^G \leq x_H^G$, sendo x_t^G o nível do gasômetro; x_H^G e x_L^G são, respectivamente, os níveis máximo e mínimo de segurança (veja a Figura 2). Quando o nível do gasômetro estiver acima do nível máximo de segurança (x_H^G), o excesso de gás é enviado para a torre de queima (*flare stack*). Por razões de segurança, cada gasômetro não pode alcançar seu nível máximo (x_{HH}^G) ou mínimo (x_{LL}^G). Normalmente, por cautela, os operadores tendem a trabalhar com o gasômetro próximo ao valor de referência conhecido como valor visado

de operação e também chamado de nível normal (x_N^G).

Figura 2: Limites operacionais de nível dos gasômetros.



Fonte: elaboração própria.

1.1.1 O problema de otimização da distribuição de gases

A decisão de ligar ou desligar i queimadores do combustível $F = \text{BFG, COG, LDG, TAR}$ ou MG na caldeira da termoelétrica j no instante t é feita pelas variáveis binárias $ub_{j,t}^{F,i}$ para $i = 1, \dots, N_{bu}$ e $j = 1, \dots, N_{bo}$, sendo N_{bu} o número total de queimadores em cada caldeira e N_{bo} o número total de caldeiras. Se $ub_{j,t}^{F,i} = 1$, então i queimadores do combustível F devem ser simultaneamente comutados para o estado ligado ou desligado no instante de tempo t na caldeira j , e quando $ub_{j,t}^{F,i} = 0$, nenhum queimador do combustível F deve ser comutado na caldeira em questão. A vazão do combustível $F = \text{BFG, COG, LDG, MG}$ ou TAR para a caldeira j é uma variável de decisão definida por $fc_j^{b,F}$, a qual pode ser ajustada continuamente numa certa faixa operacional.

Outras variáveis de decisão do problema de planejamento da distribuição dos gases siderúrgicos são: $fc_j^{m,G}$ é a vazão do gás $G = \text{BFG, COG, LDG}$ ou NG para a estação de mistura $j = 1, \dots, N_m$; N_m é o número total de estações de mistura; S_H^G é o volume de gás desperdiçado nas torres de queima dos gasômetros do gás $G = \text{BFG, COG}$ ou LDG ; S_M^j é o volume de gás misto desperdiçado nas torres de queima das estações de mistura j ; S_L^G é o volume mínimo a ser mantido no gasômetro G ; pw_j^{gen} é a potência ativa a ser gerada no turbogerador j e $f_{j,t}^{ps}$ é a vazão total da quantidade de vapor de processo extraída da caldeira j e da turbina j no instante t .

Os objetivos principais do problema de distribuição de gases siderúrgicos são: (a) escolher a mistura ideal de combustíveis para as caldeiras das termoelétricas e reduzir o consumo de alcatrão; (b) escolher a receita ideal de gases nas estações de mistura; (c) diminuir a queima de gases combustíveis nas torres de proteção dos gasômetros e estações de mistura; (d) favorecer a operação de cada gasômetro dentro da zona visada de

operação; (e) reduzir o número de comutações dos estados dos queimadores nas caldeiras das casas de força, especialmente comutações simultâneas de 2 ou mais queimadores; (e) restringir a extração de vapor nas caldeiras e turbinas; e, (f) aumentar a produção de energia elétrica.

1.1.2 O estado da arte

Alguns estudos têm formulado o problema de planejamento a curto prazo da distribuição dos combustíveis siderúrgicos como um problema de Programação Linear Inteira Mista (MILP) multi-período: Akimoto et al. (1991); Sinha et al. (1995); Kim, Yi e Han (2003a); Kim, Yi e Han (2003b); Kong et al. (2010); Zhang et al. (2011a); Zhao et al. (2015); Yang et al. (2015); Kong (2015); Oliveira, Pena e Salles (2016); Zeng et al. (2018), ou como um problema de Programação Quadrática Inteira Mista (MIQP) com horizonte de planejamento finito: Bemporad e Morari (1999). Esses trabalhos consideram que as séries temporais das vazões de produção e consumo dos gases são determinísticas, e resolvem o problema de otimização sem levar em conta os erros de previsão, isto é, assumem que os modelos de previsão são perfeitos. Uma síntese comparativa entre as mais relevantes propostas para otimização da distribuição de combustíveis siderúrgicos pode ser encontrada na Tabela 1, ao final desta seção.

Outros estudos, no entanto, consideram que incertezas nas séries temporais das vazões de produção e consumo dos gases afetam as decisões de curto prazo: Zhang et al. (2011b); Zhao et al. (2012a); Zhao et al. (2014); Zhao et al. (2017). O foco desses trabalhos é o gerenciamento da distribuição dos combustíveis siderúrgicos em tempo real, por meio de modelos preditivos baseados em dados, de forma a garantir que os gasômetros operem numa faixa operacional segura. Esses trabalhos aplicam algoritmos de aprendizagem na previsão dos níveis dos gasômetros e algoritmos de controle para garantia das restrições de segurança do gasômetro. Ou seja, esses estudos possuem duas fases:

- Na fase de previsão, os níveis dos gasômetros são estimados por aprendizagem de máquinas (ZHANG et al., 2011b) ou por redes neurais. Zhao et al. (2012a) desenvolvem uma rede neural híbrida, Zhao et al. (2014) desenvolvem uma aprendizagem de máquinas baseada em redes bayesianas (*Bayesian networks*) e Zhao et al. (2017) desenvolvem uma aprendizagem de máquinas denominada *mixed Gaussian Kernel-based prediction intervals*.
- Na fase de ajuste dos níveis dos gasômetros, os algoritmos executam rotinas que determinam ações de controle de modo a compensar o sistema. Em geral, os algoritmos de controle propostos são: a) procedimentos heurísticos Zhao et al. (2012a) e Zhao et al. (2014); e, b) técnicas de controle com horizonte rolante Zhao et al. (2017).

A presente tese propõe um algoritmo de controle com horizonte rolante para otimização da distribuição de gases siderúrgicos a partir de previsões das séries de produção

dos gases e das séries de demanda dos gases, de energia e de vapor de processo. Esse algoritmo tanto resolve problemas de otimização de larga escala (ver Harjunoski et al. (2014); Oliveira, Pena e Salles (2016); Bischi et al. (2017)), como também problemas de otimização que levam em conta incertezas nas previsões (ver Silvente et al. (2015); Silvente et al. (2018)). O algoritmo proposto usa modelos lineares e heurísticas para realizar previsões das séries temporais que serão usadas na otimização do problema MILP multi-período com horizonte finito. Das variáveis de decisão obtidas pelo algoritmo, apenas as soluções das variáveis do período atual são aplicadas à planta, as soluções dos períodos futuros são descartadas. Assim, sempre que é feita a rolagem, o algoritmo de controle atualiza a leitura dos níveis dos gasômetros que são responsáveis por absorver as incertezas das previsões. Restrições do modelo de otimização garantem que o gasômetro opere em regiões seguras e, na prática, equipamentos de segurança e proteção garantem a integridade operacional do sistema como um todo (especialmente os gasômetros). Assim, em caso extremo de excesso de produção de gás, a torre do gasômetro queima o excesso de gás ou, em outro caso extremo, as casas de força podem ser supridas com alcatrão, se necessário manter a produção de eletricidade prevista quando a produção de gás estiver aquém da previsão ou quando a eletricidade demandada for superior.

O algoritmo proposto possui, então, algumas semelhanças com a estratégia de controle com horizonte rolante usada no Controle Preditivo Baseado em Modelo, também conhecido como MPC do termo em inglês *Model-based Predictive Model* (Garcia, Prett e Morari (1989); Maciejowski (2000); Mayne et al. (2000); Camponogara et al. (2002); Mattingley, Wang e Boyd (2011)), e no EMPC (*Economic Model-based Predictive Control*) (Diehl, Amrit e Rawlings (2011); Ellis, Durand e Christofides (2014)). A principal diferença é que o MPC é usado entre os níveis de controle regulatório e de otimização, enquanto o algoritmo aqui proposto é usado no nível de otimização. Além disso, o EMPC é usado juntamente em ambos os níveis.

No entanto, existem muitas diferenças entre o algoritmo de controle por horizonte rolante apresentado por Zhao et al. (2017) e o proposto nesta tese. Em Zhao et al. (2017) são aplicadas técnicas de aprendizagem de máquinas para prever os níveis dos gasômetros, e, quando necessário, realiza-se uma ação de controle para garantir que o nível permaneça numa região de segurança. Em sua formulação não é apresentada uma equação de balanço de massa e não é considerada a possibilidade de queima nem escassez de gás nos gasômetros. Isto é, assume-se que a ação de controle no gasômetro é suficiente e rápida para: evitar a queima, caso a previsão aponte que o nível irá ultrapassar o limite superior de segurança; ou, também, evitar a escassez, caso a previsão aponte que o nível irá ficar abaixo do limite mínimo de segurança.

Para que essa ação de controle seja exequível, Zhao et al. (2017) teve que fazer com que o horizonte de controle fosse pequeno, no caso, 1 minuto. Porém, há problemas nesta solução, pois o horizonte de controle deve ter duração suficiente para que as variáveis de controle calculadas sejam enviadas aos controladores locais. Entretanto, na maioria das

plantas reais, o intervalo entre otimizações precisa ser maior que 1 minuto (Akimoto et al. (1991); Kim, Yi e Han (2003a); Kong et al. (2010); Oliveira, Pena e Salles (2016), entre outros apresentados na Tabela 1), pois o tempo para ligar ou desligar queimadores, para estabilizar vazões de vapor nas caldeiras e para estabilizar vazões dos gases nas termoelétricas e estações de mistura pode ser maior que 1 minuto.

Esta tese, por outro lado, propõe o uso de modelos lineares de previsão e técnicas heurísticas na estimativa das séries individuais de produção e consumo de gases siderúrgicos, vapor e energia, e, então, baseado em previsões, o algoritmo de otimização realiza a distribuição dos combustíveis, controlando seu uso nos consumidores controlados pelo centro de energia. Portanto, as unidades de controle são as termoelétricas e as estações de mistura, mas não os gasômetros. Assim, o gasômetro atua, conforme sua designação, como um reservatório de gás, e quando necessário, ocorre queima ou escassez. No caso, pesos são usados na função objetivo do problema de otimização com o objetivo de diminuir o volume de gás queimado nas torres de proteção dos gasômetros e diminuir eventos de escassez; restrições garantem o balanço de massa do modelo MILP e, portanto dos gasômetros, assim como a operação segura dos demais equipamentos do sistema.

Assim, o uso do modelo MILP multi-período foi favorável ao aumento da duração do horizonte de controle que, neste caso, é 12 vezes maior que em Zhao et al. (2017). Como consequência espera-se, por exemplo, que ocorram menos comutações de queimadores nas centrais termoelétricas, possibilitando menos intervenções e maior estabilidade operacional das caldeiras, podendo resultar numa maior eficiência energética. Mas também, como o tempo necessário para a realização de todas as previsões é menor que o intervalo de aquisição de dados e também menor que o tempo necessário para a execução do algoritmo de otimização, é possível, se necessário, executar o algoritmo aqui proposto considerando o horizonte de controle com período menor. Porém, no caso do algoritmo proposto em Zhao et al. (2017), não seria vantajoso executá-lo considerando o período do horizonte de controle maior do que o utilizado pelos autores, pois neste caso, em muitas situações não seriam factíveis ações de controle sem queima e/ou escassez nos gasômetros.

Com relação aos modelos de previsão, nesta tese as previsões das séries temporais sazonais, como as séries individuais do consumo de gás BFG nos altos-fornos e na coqueria e do consumo de gás COG nos altos-fornos e na coqueria, são feitas pelo Método de Suavização Exponencial Sazonal de Holt-Winters (ver Montgomery, Jennings e Kulahci (2008)). Neste caso, as constantes de suavização são calculadas por algoritmo genético (SIMON, 2013). Em contrapartida, as previsões das séries temporais sem sazonalidade, como as séries individuais de produção do gás BFG e do COG, consumo de MG no processo HSM e demanda de eletricidade, são feitas por Modelo Auto-Regressivo Integrado de Média Móvel (BOX et al., 2015) com parâmetros adaptativos; ou, por modelos de Média Móvel, como nas previsões das séries individuais de consumo do gás BFG no PCI e do gás LDG na calcinação, e da demanda de extração de vapor de processo nas caldeiras

e turbinas. As previsões das séries individuais de produção do gás LDG são realizadas por um procedimento heurístico, levando em consideração a programação do sopro de oxigênio nos convertedores da aciaria. Isso ocorre porque as características destas séries mudam bastante, sendo algumas delas possíveis de serem estimadas por modelos de séries temporais sazonais e outras, não. Em todo caso, os parâmetros dos modelos são estimados toda vez em que ocorre o deslizamento, pois como será visto, não foi possível encontrar modelos com parâmetros fixos que realizassem estimativas com erros menores que os modelos com parâmetros adaptativos.

Modelos lineares de previsão foram usados na previsão das séries de produção e consumo dos gases BFG e COG, como em Jeong et al. (2011) que propuseram o uso de modelos de média móvel para realizar tais previsões. No entanto, Jeong et al. (2011) não propôs nenhum tipo de controle automático; além disso, os parâmetros dos modelos de previsão são fixos e obtidos de modo empírico. Porém, como essas séries temporais costumam apresentar muitas não-linearidades devido, entre outros fatores, a intensas variações nas dinâmicas de produção, consumo e armazenamento dos gases (ver Zhang et al. (2011b); Zhao et al. (2012a); Zhao et al. (2012b); Zhao et al. (2012c); Zhao et al. (2014); Zhao et al. (2017)), então modelos com parâmetros invariantes no tempo podem gerar previsões com grande incertezas, por essa razão é preciso re-calcular periodicamente os parâmetros do modelo. Nesses artigos, não foram propostos modelos para as séries de demanda de eletricidade, vapor de processo dentre outras séries temporais.

Outros estudos, no entanto, aplicam algoritmos de aprendizagem de máquinas para realizar previsões. Assim, Zhao et al. (2012b) aplicam máquinas de vetores de suporte com mínimos quadrados ou *least square support vector machine* (LS-SVM) para realizar previsões das séries de produção e consumo de BFG; e, Zhao et al. (2012c) usam modelos de regressão por vetores-suporte via mínimos quadrados aplicados à aprendizagem de múltiplos núcleos, isto é, *multiple kernel learning-based least square support vector regression* (MKL-LSSVR) para realizar previsões das séries de produção e consumo de BFG e do nível do gasômetro de BFG. Esses trabalhos, assim como Jeong et al. (2011) realizam apenas previsões, e não estão preocupados com as etapas de otimização nem controle.

Zhang et al. (2011b), por sua vez, aplicam aprendizagem de máquinas nas previsões dos níveis dos gasômetros; Zhao et al. (2012a) usam redes neurais para realizar previsões da série do nível do gasômetro de COG e das séries de produção e consumo de COG, Zhao et al. (2014) desenvolvem redes bayesianas para previsões dos níveis dos gasômetros de BFG e LDG; e, Zhao et al. (2017) desenvolvem uma aprendizagem de máquina baseada em *mixed Gaussian Kernel-based prediction intervals* para prever os níveis dos gasômetros de BFG, COG e LDG, e a série de demanda de eletricidade.

Quanto à sintonia dos parâmetros do modelo MILP do problema de distribuição de gases siderúrgicos, a escolha dos valores das penalidades da função objetivo não é uma tarefa fácil nem uma questão concluída. Entre as dificuldades encontradas, a maior é a

determinação dos custos operacionais dos gasômetros e dos queimadores, pois são custos difíceis de estipular (ZHAO et al., 2015). Além disto, há vários conflitos entre as ponderações destes pesos, de sorte que, em algumas situações, é quase inevitável se fazer algumas análises de sensibilidade para verificação do efeito das escolhas realizadas no comportamento do sistema (OLIVEIRA; PENA; SALLES, 2016).

Embora poucos, há alguns trabalhos que fornecem algumas orientações acerca de procedimentos para ajustes das penalidades para o modelo MILP da distribuição de combustíveis siderúrgicos. Dentre os trabalhos, destacam-se dois: no primeiro deles, Zhao et al. (2015) aplicam o conceito de otimalidade de Pareto para ajuste dos parâmetros, obtendo sintonias adequadas de modo a encontrar um equilíbrio entre dois índices conflitantes, um relacionado aos desvios dos níveis dos gasômetros e outro relacionado às comutações dos queimadores nas termoelétricas; no segundo deles, Oliveira, Pena e Salles (2016) apresentam um procedimento heurístico baseado em análises de sensibilidade.

Oliveira, Pena e Salles (2016) propõem cinco indicadores para medir a qualidade da sintonia do modelo MILP. Todavia, esses indicadores não estão normalizados, por essa razão, os autores usaram artifícios para minimizar o impacto de alguns deles; além disso, cada indicador possui uma unidade de medida diferente das unidades dos demais. Como no restante do trabalho, os indicadores são avaliados por meio de análise de sensibilidade, seu emprego foi bem sucedido para a finalidade ali proposta. No entanto, o procedimento proposto requer que especialistas realizem análises de sensibilidade, restringindo o uso do procedimento e dificultando seu uso de modo reiterado numa rotina automática de sintonia. Outro problema é que não há uma investigação ampla do espaço de busca, pois a heurística não possui um mecanismo de busca por novos trajetos de solução durante sua execução.

Antes de Zhao et al. (2015) e Oliveira, Pena e Salles (2016), os parâmetros do modelo MILP foram obtidos de modo empírico por Kim, Yi e Han (2003a). Nos demais trabalhos, os valores dos parâmetros são apenas citados: (AKIMOTO et al., 1991); (KONG et al., 2010); (ZHANG et al., 2011a); (KONG, 2015); (YANG et al., 2015) e (ZENG et al., 2018), e em outros trabalhos, os valores não são apresentados (SINHA et al., 1995).

1.2 Originalidade da tese

Nesta tese, para sintonia dos parâmetros do modelo MILP, é proposto o uso do algoritmo de otimização por enxame de partículas. Os indicadores propostos em Oliveira, Pena e Salles (2016) aqui são normalizados. Uma das principais vantagens do procedimento aqui proposto é que a sintonia pode ser programada para ocorrer automaticamente, pois o algoritmo consiste numa rotina puramente computacional, sem que seja necessária uma avaliação de um especialista em otimização. Mas a principal diferença entre esses trabalhos é que, no trabalho precedente, o algoritmo de controle por horizonte rolante é suprido por previsões sem incertezas.

As contribuições originais desta tese estão resumidas a seguir:

1. Desenvolvimento de um algoritmo de controle por horizonte rolante aplicado ao problema da otimização da distribuição de gases siderúrgicos numa usina siderúrgica integrada, considerando incertezas nas previsões das séries temporais.
2. Formulação de modelos lineares de previsão com parâmetros adaptativos nas séries individuais de produção dos gases siderúrgicos, de consumo de gases siderúrgicos em processos não-controlados pelo centro de energia, e das demandas de gás misto para o processo de laminação, de vapor de processo para processos diversos e de eletricidade pela indústria.
3. Desenvolvimento de um procedimento heurístico para previsão da produção do gás LDG, cuja produção ocorre em bateladas, isto é, de forma intermitente.
4. Desenvolvimento de um procedimento para sintonia dos parâmetros do modelo MILP baseado na otimização por enxame de partículas.
5. Definições de indicadores normalizados para avaliação do desempenho do modelo MILP.

A Tabela 1 apresenta um resumo para comparações entre as principais contribuições da presente tese e as contribuições dos trabalhos mais relevantes sobre o problema em questão.

Tabela 1: Comparação entre as mais relevantes propostas de otimização da distribuição de combustíveis siderúrgicos.

(continua)

Trabalho	Técnica de gerenciamento	Modelos de Previsão	Sintonia de Parâmetros	Indicadores de desempenho
Akimoto et al. (1991)	Modelo de otimização MILP: com $h_s = h_f = 8$ horas e $\Delta T = 2$ horas.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Sinha et al. (1995)	Modelo de otimização MILP.	Perfeito (determinístico)	Valores não informados	Sem indicadores
Bemporad e Morari (1999)	MPC com modelo de otimização MIQP: com $h_s = 60$ horas, $h_f = 60$ horas e $\Delta T = 2$ horas.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Kim, Yi e Han (2003a)	Modelo de otimização MILP multi-período: com $h_s = 25$ min., $h_f = 25$ min. e $\Delta T = 5$ min.	Perfeito (determinístico)	Procedimento empírico	Sem indicadores
Kim, Yi e Han (2003b)	Modelo de otimização MILP multi-período: com $h_s = 25$ min., $h_f = 25$ min. e $\Delta T = 5$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Kong et al. (2010)	Modelo de otimização MILP multi-período: com $h_s = 130$ min., $h_f = 130$ min. e $\Delta T = 15$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Jeong et al. (2011)		Séries temporais: da produção e consumo de BFG e COG. Procedimento heurístico baseado em média móvel (BFG e COG). $h_f = 60$ min. para BFG e COG. $\Delta T = 30$ s.		

Tabela 1: Comparação entre as mais relevantes propostas de otimização de distribuição de combustíveis siderúrgicos.

Trabalho	Técnica de gerenciamento	Modelos de Previsão	Sintonia de Parâmetros	Indicadores de desempenho (continuação)
Zhang et al. (2011a)	Modelo de otimização MILP multi-período: com $h_s = 60$ min., $h_f = 60$ min. e $\Delta T = 12$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Zhang et al. (2011b)		Séries Temporais dos níveis dos gasômetros com parâmetros adaptativos. Técnica baseada em aprendizagem de máquinas com gradiente descendente + QGA^{*1} , e com $h_f = 30$ min. e $\Delta T = 1$ min.		Não-normalizados
Zhao et al. (2012a)	Otimização com regras de controle baseadas em heurísticas com: $h_c = 1$ min., $h_f = 30$ min., $\Delta T = 1$ min e $T = 1$ min.	Séries temporais: do nível do gasômetro de COG, da produção e consumo de COG. Rede Neural - GP baseado em ESN^{*2} .		
Zhao et al. (2012b)		Séries temporais de produção total e consumo total de BFG. $LS-SVM^{*3}$ com parâmetros ajustados por otimização hiperparamétrica. $h_f = 60$ min., $\Delta T = 1$ min. e $T = 10$ min.		

Tabela 1: Comparação entre as mais relevantes propostas de otimização da distribuição de combustíveis siderúrgicos.

Trabalho	Técnica de gerenciamento	Modelos de Previsão	Sintonia de Parâmetros	Indicadores de desempenho
Zhao et al. (2012c)		Séries temporais: do nível do gasômetro de BFG, da produção e consumo de BFG. Procedimento heurístico inspirado em MKL-LSSVR baseado em MGR^{*4} . $h_f = 30$ min. e $\Delta T = 1$ min.		(continuação)
Zhao et al. (2014)	Otimização baseada em heurística fundamentada na Teoria Bayesiana. Com $h_s = 30$ min. e $T = 1$ min.	Séries dos níveis dos gasômetros de BFG e LDG. Rede Bayesiana. $h_f = 30$ min e $\Delta T = 1$ min.		
Yang et al. (2015)	Modelo de otimização MILP multi-período: com $h_s = 2$ horas, $h_f = 2$ horas e $\Delta T = 15$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Kong (2015)	Modelo de otimização MILP multi-período: com $h_s = 130$ min., $h_f = 130$ min. e $\Delta T = 15$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Zeng e Sun (2015)	Modelo de otimização PSO com $h_s = h_f = 24$ horas e $\Delta T = 60$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Zhao et al. (2015)	Modelo de otimização MILP multi-período: com $h_s = 36$ min., $h_f = 36$ min., $\Delta T = 1$ min. e $T = 6$ min.	Perfeito (determinístico)	Otimidade de Pareto	Não-normalizados

Tabela 1: Comparação entre as mais relevantes propostas de otimização da distribuição de combustíveis siderúrgicos.

(conclusão)

Trabalho	Técnica de gerenciamento	Modelos de Previsão	Sintonia de Parâmetros	Indicadores de desempenho
Oliveira, Pena e Salles (2016)	Algoritmo de horizonte rolante com modelo de otimização MILP multi-período: com $h_s = 24$ horas, $h_f = 1$ hora, $\Delta T = 1$ min. e $T = 12$ min.	Perfeito (determinístico)	Heurística	Não-normalizados
Zhao et al. (2017)	Algoritmo de horizonte rolante com otimização heurística baseada em <i>mixed Gaussian kernel-based prediction intervals</i> com $h_c = 1$ min., $h_s = 60$ min. e $h_f = 20$ min.	Previsão das séries dos gases baseada em heurísticas de dados.		
Zeng et al. (2018)	Modelo de otimização MILP multi-período: com $h_s = h_f = 6$ horas e $\Delta T = 60$ min.	Perfeito (determinístico)	Valores empíricos	Sem indicadores
Pena, Oliveira e Salles (2019)*5	Algoritmo de horizonte rolante com modelo de otimização MILP multi-período: com $h_s = 24$ horas, $h_f = 1$ hora, $h_c = 12$ min., $\Delta T = 1$ min. e $T = 12$ min.	Modelos lineares e heurística - previsão das séries de produção e consumo dos gases, e de demanda de vapor de processo e eletricidade.	Heurística proposta por Oliveira, Pena e Salles (2016)	Não-normalizados
Tese proposta	Algoritmo de horizonte rolante com modelo de otimização MILP multi-período: com $h_s = 24$ horas, $h_f = 1$ hora, $h_c = 12$ min., $\Delta T = 1$ min. e $T = 12$ min.	Modelos lineares e heurística - previsão das séries de produção e consumo dos gases, e de demanda de vapor de processo e eletricidade.	PSO*6	Não-normalizados

Fonte: elaboração própria.

Sendo que: h_s é o horizonte de planejamento; h_f é o horizonte de previsão; h_c é o horizonte de controle; ΔT é o intervalo de amostragem e T é o período de otimização. QGA*1 (Quantum Genetic Algorithm) - Algoritmo Genético com inspiração Quântica. ; GP based ESN*2 - (Gaussian Process-based Echo States Network); LS-SVM*3 (least square support vector machine) - Máquinas de Vetores de Suporte com Mínimos Quadrados; MKL-LSSVR based on MGR*4 (Multiple Kernel Learning - Least Squares Support Vector Regression based on Reduced Gradient Method) - LSSVR baseado em MKL inspirado no Método do Gradiente Reduzido.; Pena, Oliveira e Salles (2019)*5 - Artigo resultante da tese proposta; e, PSO*6 (Particle Swarm Optimization) - Otimização por nuvem de partículas.

1.3 Justificativas

As estratégias para resolver problemas de planejamento com incertezas podem ser classificadas em reativas e pró-ativas. As estratégias reativas tendem a realizar ajustes na política obtida pelo cálculo do modelo determinístico de modo a compensar as alterações, modificações, incertezas e/ou erros à medida que os dados são atualizados (LI; IERAPETRITOU, 2008). As estratégias pró-ativas são baseadas na consideração de todos os casos possíveis e na busca de uma boa solução para todos esses casos (SILVENTE et al., 2015).

As estratégias pró-ativas têm a vantagem de encontrar uma solução viável para todos os cenários considerados. No entanto, esta solução tende a ser muito conservadora, pois o modelo deve levar em conta todas as possibilidades, mesmo aquelas que não ocorrem eventualmente. As técnicas pró-ativas mais usadas são: a otimização robusta (LI; DING; FLOUDAS, 2011) e a programação estocástica (SHAPIRO et al., 2013).

As estratégias reativas, como a proposta nesta tese, têm a vantagem de trabalhar com modelos mais simples e serem algoritmos mais rápidos, pois não precisam levar em consideração todos os possíveis cenários de operação (SILVENTE et al., 2018). Além disso, a solução, por ser menos conservadora, pode possibilitar um maior rendimento, embora exista o risco de uma solução viável não ser encontrada em alguns cenários. Além disso, por não levar em conta todas as possibilidades e por conta dos erros de previsão, as soluções encontradas são sub-ótimas. Os métodos reativos mais usados são: o controle por horizonte deslizante (LI; IERAPETRITOU, 2010) e o MPC (OBERDIECK; PISTIKOPOULOS, 2015).

A estratégia de controle com horizonte rolante leva em conta, sistematicamente, as restrições do problema durante seu projeto e implementação, logo é bem sucedida em permitir ao sistema operar nos extremos sem violar alguma restrição. Deste modo, as estratégias reativas têm sido amplamente aplicadas em indústrias petro-químicas (MAYNE et al., 2000) e afins (LI; DING; FLOUDAS, 2011), onde a exigência pela máxima eficiência provoca sua operação em pontos sobre ou bem próximo da fronteira do conjunto de estados e controles admissíveis (Sand et al. (2000); Sand e Engell (2004); Janak e Floudas (2006); Shaik et al. (2009); Zhao et al. (2017); Silvente et al. (2018)).

Nesta tese, as incertezas do problema de planejamento da distribuição de gases siderúrgicos, modelado como um problema MILP multi-período, são tratadas por algoritmo de horizonte rolante que resolve iterativamente o problema determinístico, avançando o horizonte de otimização em cada iteração; assumindo que desde que as informações sobre o estado do sistema sejam atualizadas, a solução ótima para o novo cenário resultante pode ser encontrada. Essa estratégia considera um horizonte de previsão durante o qual os dados futuros, conhecidos por meio de modelos de previsão, são usados no problema de otimização; e um horizonte de controle durante o qual as decisões resultantes da otimização do problema, a partir das informações dos modelos de previsão, são aplicadas.

A partir do modelo de otimização e dos modelos de previsão, o otimizador fornece os seguintes sinais de controle: (a) de vazão de cada combustível a ser utilizado em cada cal-

deira; (b) do número e tipo de queimadores a serem acesos ou apagados em cada caldeira; (c) de vazão de cada combustível a ser utilizado em cada misturadora para produzir gás misto na quantidade necessária e dentro dos padrões de qualidade; (d) potência elétrica a ser gerada em cada grupo turbo-gerador; (e) vazão de vapor de processo a ser produzido em cada central termoelétrica; (f) de vazão e local onde deve ser feita extração de vapor de processo (quais caldeira e quais turbinas); (g) qual volume de gás e em qual período deve ser enviado à torre de queima para salvaguardar a integridade física dos gasômetros e da rede de distribuição de gases.

O procedimento iterativo desta estratégia permite a atualização de todas as informações do problema e ajustes dos parâmetros do modelo de otimização, favorecendo a otimização. Segundo Kopanos e Pistikopoulos (2014), as estratégias para solução de problemas do tipo planejamento de curto prazo não devem apenas ser capazes de gerar soluções boas, mas também de possibilitar que o sistema reaja rapidamente às mudanças inesperadas e revise a política de soluções do problema. Como a maioria dos problemas de planejamento de curto prazo é de processo dinâmico, esses problemas devem ser resolvidos de modo reativo, num intervalo de tempo suficientemente curto, a fim de capturar eficientemente as necessidades do problema, levando em conta o estado do sistema e as informações atualizadas da planta (KOPANOS; PISTIKOPOULOS, 2014). Por este motivo, esta tese resolve o problema de planejamento de curto prazo do sistema de distribuição de gases com incertezas a partir da resolução sucessiva (iterativamente) de problemas de otimização, e compartilha muitos conceitos com problemas típicos de controle.

1.4 Objetivos geral e específicos

Enfim, como o tema envolve, em grande proporção, a questão energética e ambiental, portanto também econômica, o problema é ainda mais importante hoje do que quando formulado pela primeira vez. O uso racional dos rejeitos gasosos oriundos das etapas de fabricação do aço nos complexos siderúrgicos, nos processos termo-químicos, na produção de vapor de processo e geração elétrica é imprescindível diante de um cenário de constante aumento dos preços de energia e no qual as questões ambientais adquirem maior relevância. Por esta razão, a presente tese busca contribuir, em alguns pontos, com o aperfeiçoamento dos métodos de otimização da distribuição de gases siderúrgicos para cogeração.

Como apresentado, embora existam vários trabalhos acerca do assunto, e sob diversas perspectivas, ainda restam em aberto muitas questões que confirmam os desafios e a complexidade acerca da Otimização da Distribuição de Gases Siderúrgicos. Um dos pontos ainda pendentes para o qual a presente tese propõe solução, envolve questões sobre como realizar a Otimização em tempo real da Distribuição de Gases Siderúrgicos numa Usina Real. Para cumprir esta tarefa, é proposto um algoritmo de controle responsável por permitir a operação segura do sistema e corrigir os erros oriundos das incertezas de previsões.

A principal publicação resultante desta tese é Pena, Oliveira e Salles (2019). Neste artigo, o algoritmo de controle por horizonte rolante proposto é aplicado ao modelo MILP Multi-período proposto em Oliveira, Pena e Salles (2016), que por sua vez é uma das publicações secundárias. Em Oliveira, Pena e Salles (2016), são propostas, entre outras contribuições, melhorias na modelagem MILP multi-período, um procedimento heurístico para ajuste dos parâmetros do modelo e indicadores de desempenho.

Como trabalhos secundários, dentre os mais recentes trabalhos oriundos da tese em questão, estão: (CREMASCO; PENA; SALLES, 2016), (PENA; OLIVEIRA JÚNIOR; SALLES, 2016a) e (PENA; OLIVEIRA JÚNIOR; SALLES, 2016b). O primeiro destes artigos disserta sobre a aplicação do método de Holt-Winters para previsão do consumo dos gases siderúrgicos e os dois seguintes discorrem sobre análises de sensibilidade do modelo formulado por Oliveira, Pena e Salles (2016). O segundo artigo avalia o impacto do custo do alcatrão no sistema e o terceiro traz um registro sobre os efeitos que diferentes combinações das penalidades dos equipamentos (gasômetros e queimadores) causam no sistema de distribuição de gases para cogeração.

1.5 Organização da tese

Esta tese está organizada da seguinte forma:

O Capítulo 1 realiza uma explanação geral a respeito do sistema de distribuição de combustíveis siderúrgicos, sendo apresentados os desafios para gerenciamento deste sistema e os problemas em operá-lo. A relevância e a originalidade do tema são apresentadas à medida que é feita a revisão bibliográfica, sendo esclarecidas as contribuições desta Tese e as justificativas das estratégias adotadas.

O Capítulo 2 apresenta o algoritmo de controle proposto, o modelo do problema de otimização e o otimizador. Os resultados deste algoritmo foram publicados na revista *Computers and Chemical Engineering*. Na seqüência, neste capítulo, é proposto um algoritmo de otimização por enxame de partículas para sintonia dos parâmetros do modelo de otimização, e também a normalização dos indicadores de desempenho.

O Capítulo 3 aborda os modelos de previsão das séries temporais. Neste capítulo é proposta a aplicação de modelos ARIMA adaptativo para realizar as previsões das séries de produção de BFG nos altos-fornos e COG na coqueria, de consumo de MG no processo HSM e da demanda de eletricidade. Também são propostas aplicações de modelos de Holt-Winters com parâmetros adaptativos para previsão das séries de consumo dos gases BFG e COG nos altos-fornos e na coqueria. No entanto, para previsão da produção de LDG é apresentada uma solução heurística, enquanto que um procedimento de média móvel é proposto para previsão das séries de consumo de BFG no PCI e demanda de vapor de processo. Estudos de casos são usados para verificação da qualidade dos resultados obtidos através do uso das técnicas propostas.

No Capítulo 4, são apresentados os resultados de simulações computacionais do algoritmo de controle por horizonte rolante proposto, o qual foi aplicado ao modelo MILP

cujas equações estão descritas no Capítulo 2 e que foi suprido por séries temporais cujos modelos de previsão são estudados no Capítulo 3. Além disso, também serão apresentados resultados e avaliações sobre a aplicação do algoritmo de otimização por enxame de partículas à sintonia dos parâmetros do modelo MILP.

O Capítulo 5 apresenta as principais conclusões sobre a tese. São tecidos comentários sobre os resultados obtidos, sobre os problemas encontrados, incluindo observações sobre oportunidades de melhorias e perspectivas para estudos futuros.

2 *Otimização da distribuição de gases siderúrgicos em tempo real*

Neste capítulo, o algoritmo de controle por horizonte rolante é apresentado na Seção 2.1. Esse algoritmo foi aplicado ao modelo Linear Inteiro Misto multi-período (MILP) do problema de otimização do sistema de distribuição de gases siderúrgicos. Na Seção 2.2 é apresentado o algoritmo de otimização e na Seção 2.3 é apresentado o algoritmo de otimização por enxame de partículas, o qual pode ser usado na sintonia dos parâmetros do modelo.

2.1 O algoritmo de horizonte de rolagem

O algoritmo de horizonte rolante proposto é descrito pelos seguintes passos:

Passo 1) Faça $iter = 0$ e $t = t_0$ sendo t_0 o tempo inicial de planejamento. Seja o tempo total de planejamento igual a T_s e o tempo total de previsão igual a T_f . Para um intervalo de amostragem igual a T , determine o horizonte de planejamento $h_s = \frac{T_s}{T}$, o horizonte de previsão $h_f = \frac{T_f}{T}$ e o horizonte de controle h_c de modo que $1 \leq h_c \leq h_f$. O número total de iterações é dado pela expressão:

$$t_{it} = \text{int}\left(\frac{h_s}{h_c}\right)$$

, sendo $\text{int}(z)$ o valor inteiro de z .

Passo 2) A estimativa k -passos-à frente para $k = 1, \dots, h_f$ das séries temporais é feita a partir de um conjunto de dados passados até o instate atual t . As séries temporais estimadas são: a) produção total de gás (Fp_{t+kT}^G) para $G = \text{BFG, COG, LDG}$; b) consumo total não-controlado de gás (Fc_{t+kT}^G) para $G = \text{BFG, COG, LDG}$; c) demanda de gás misto para consumo no processo HSM ($fc_{t+kT}^{m, hsm}$); d) demanda de vapor de processo (D_{t+kT}^{ps}); e) demanda de eletricidade (D_{t+kT}^E). Essas séries de previsão são usadas nas restrições do problema de otimização.

Passo 3) Calcule o problema de otimização MILP cuja Função Objetivo é expressa pela Equação (2.1):

$$J(t) = \sum_{k=0}^{h_f} J_{op}(t + kT) + J_{ec}(t + kT), \quad (2.1)$$

e cujas restrições são apresentadas na Seção 2.1.1,

A parcela J_{op} é relativa aos custos operacionais dos gasômetros e dos queimadores e é calculada pela Equação (2.2)

$$\begin{aligned}
J_{op}(t) = & \sum_G (W_H^G S_{H,t}^G + W_L^G S_{L,t}^G) + \sum_G (W_{d^+}^G S_{d^+,t}^G + W_{d^-}^G S_{d^-,t}^G) + \\
& + \sum_{j=1}^{N_m} W_M^j S_{M,t}^j + \sum_{j=1}^{N_{bo}} \sum_F \sum_{i=1}^{N'_{bu}} W_{sw}^{F,i} u b_{j,t}^{F,i}, \quad (2.2)
\end{aligned}$$

em que G lista o conjunto de gases (BFG , COG ou LDG) e o índice F lista conjunto dos combustíveis (que pode ser o óleo TAR ou gases BFG , COG , LDG ou MG).

As penalidades $W_{d^+}^G$ e $W_{d^-}^G$ atuam, respectivamente, para qualquer desvio ligeiramente acima ($S_{d^+}^G$) ou abaixo ($S_{d^-}^G$) do nível x_N^G do gasômetro G (veja Figura 2); o peso W_H^G atua quando há queima de gás na torre de proteção do gasômetro e o peso W_L^G atua quando o gasômetro fica abaixo do nível mínimo de segurança (x_L^G). Essas penalidades são expressas em ($US\$/m^3$). A constante W_M^j ($US\$/m^3$) é a penalidade pela queima de gás misto na torre de proteção da estação misturadora j devido ao excesso de produção de gás misto. As penalidades devido às comutações simultâneas de i queimadores de certo combustível na fornalha da caldeira j no período t são dadas por $W_{sw}^{F,i}$, $i = 1, 2, \dots, N'_{bu}$ em $US\$/i$ unidades, sendo N'_{bu} o número máximo de comutações simultâneas na caldeira de modo que $N'_{bu} \leq N_{bu}$.

A parcela J_{ec} na função objetivo é relativa aos custos econômicos referentes ao consumo do combustível F nas caldeiras e ao consumo de gás G nas estações de mistura; ao consumo de vapor de processo nos processos siderúrgicos; e à receita com a geração elétrica nas turbinas $j = 1, \dots, N_T$ da casa de força (em que N_T é o número total de turbinas). Essa parcela é expressa pela Equação (2.3),

$$\begin{aligned}
J_{ec}(t) = & \sum_{j=1}^{N_{bo}} \sum_F C^F f c_{j,t}^{b,F} + \sum_{j=1}^{N_m} \sum_G C^G f c_{j,t}^{m,G} + \\
& + C^{PS} \sum_{j=1}^{N_{bo}} f_{j,t}^{ps} - C^{Elec} \sum_{j=1}^{N_T} p w_{j,t}^{gen}, \quad (2.3)
\end{aligned}$$

na qual C^F é o custo do combustível $F = BFG, COG, LDG, MG$ ou TAR em $US\$/m^3$ ou $US\$/kg$ consumido nas termoeletricas ou nas estações de mistura, C^{PS} é o custo do vapor de processo em $US\$/kg$ e C^{Elec} é o preço da eletricidade fornecida em $US\$/kWh$.

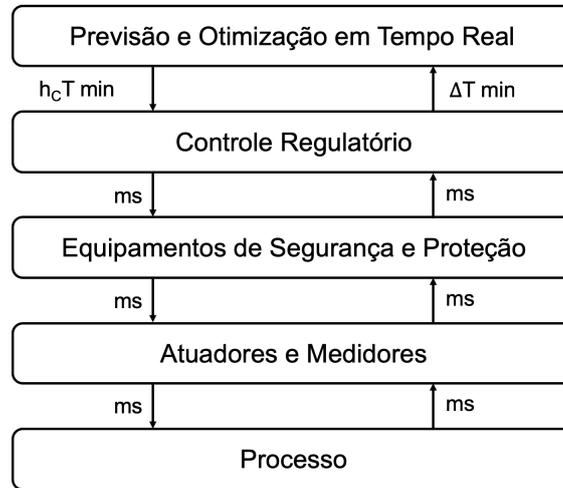
Passo 4) Após otimização, são enviadas as variáveis de decisão correspondentes aos períodos discretos $t + kT$ para $k = 0, \dots, h_c - 1$ para os controladores regulatórios das unidades siderúrgicas (termoeletricas e estações de mistura), sendo descartadas os valores das variáveis de decisão associados aos demais valores futuros $t + kT$ para $k = h_c \dots h_f$.

Passo 5) Faça $iter = iter + 1$, $t = t_0 + iter \cdot h_c \cdot T$ e retorne ao Passo 1 se $iter \leq t_{it}$. Senão, pare.

O algoritmo de horizonte rolante proposto pode ser usado no nível de otimização em

tempo real de acordo com a hierarquia de controle de processos apresentada em Seborg et al. (2016) (veja Figura 3 - na qual min é a abreviatura para minutos e ms é a abreviatura para milissegundos).

Figura 3: Hierarquia de Controle de Processos.



Fonte: adaptado de Seborg et al. (2016).

O algoritmo proposto recebe as medições das variáveis a cada intervalo de medida $\Delta T < T$ e realiza previsões a cada intervalo de tempo $h_c \cdot T$. Em seguida, o algoritmo calcula as variáveis de decisão (também conhecidas na literatura de controle de processo como *setpoints*) resolvendo o problema de otimização MILP. A janela móvel de dados históricos é definida por:

$$Mw_t = \{Z_{t-n\Delta T}, \dots, Z_{t-\Delta T}, Z_t\}, \quad (2.4)$$

em que n é o tamanho da janela móvel, Z_t é o vetor de uma das variáveis medidas e $\Delta T < T$.

O tempo de amostragem ΔT deve ter duração suficiente para permitir que os modelos de previsão capturem os detalhes do sinal medido, como sazonalidade nas séries de consumo dos gases BFG e COG e variações abruptas na produção de LDG. O horizonte de controle $h_c \cdot T$ deve ter duração suficiente para que os *setpoints* calculados sejam enviados aos controladores locais para ligar ou desligar os queimadores das caldeiras, ajustar as vazões de distribuição dos gases aos valores desejados, acionar as válvulas de proteção dos níveis dos gasômetros etc. No estudo de casos desta tese, o tamanho da janela móvel é de $n = 480$ amostras (que equivalem a 8 horas), e utiliza-se $\Delta T = 1$ min e $T = 12$ min.

Essa formulação permite a atualização do estado do sistema e ajustes de parâmetros em função das incertezas como erros de previsão da produção, do consumo e das demandas de gases, vapor de processo e eletricidade. Na prática, a solução do problema no horizonte de planejamento obtida em cada horizonte de previsão é sub-ótima, pois as previsões possuem erros e não são consideradas as informações futuras além do horizonte de previsão (KOPANOS et al., 2008). Apesar disso, desde que o horizonte de previsão seja apropriado, é possível obter boas soluções (SILVENTE et al., 2015). Porém, o tamanho do

horizonte de previsão depende das características do problema (ver Kopanos e Pistikopoulos (2014)).

O tempo computacional, para o algoritmo fornecer uma solução, depende das dimensões do problema e das características dos processos do sistema, o qual depende também do tamanho do horizonte de previsão. Assim, intervalos de tempo longos podem produzir soluções de baixo rendimento (HARJUNKOSKI et al., 2014) ou mesmo impraticáveis, tendo em vista o impacto de incertezas na estabilidade do sistema sem ajustes num intervalo considerável; e, intervalos de tempo curtos podem aumentar bastante o esforço computacional, tornando impraticável o cálculo (HARJUNKOSKI et al., 2014) ou mesmo prejudicar a estabilidade do sistema agora por conta de instabilidades produzidas durante o transitório da aplicação dos sinais de controle no sistema.

O algoritmo de controle do sistema de distribuição de combustíveis siderúrgicos, incluindo o modelo MILP multi-período e o algoritmo que determina os valores ótimos do modelo de otimização, assim como os modelos de previsão e o algoritmo usado para escolha dos parâmetros do modelo de otimização foram implementados no *MATLAB*[®].

A razão para essa escolha é porque o modelo do processo e o algoritmo de otimização aplicados são resultados de um projeto de pesquisa e desenvolvimento tecnológico, realizado via cooperação entre as instituições ArcelorMittal Brasil S/A, Universidade Federal do Espírito Santo (UFES) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), com apoio do Programa RHAE – Pesquisador na Empresa, processo do CNPq n^o458294/2012 – 8. Neste projeto, a equipe de pesquisadores foi orientada a desenvolver todas as soluções em *MATLAB*[®], pois é o *software* cuja licença a empresa possui e que apresenta vantagens para operação em conjunto com outras soluções que a empresa realiza em outros projetos. Atualmente, na empresa há um servidor do otimizador que executa, em modo *off-line*, simulações e testes de estratégias de operação do sistema de distribuição de combustíveis (OLIVEIRA JÚNIOR, 2016).

2.1.1 Restrições do Modelo MILP

O modelo proposto permite a minimização da função objetivo (Equação (2.1)) e as restrições, apresentadas logo na seqüência, são similares às restrições propostas por Oliveira, Pena e Salles (2016), acrescidas das restrições de balaço volumétrico nas estações de mistura publicadas em Pena, Oliveira e Salles (2019).

A Equação (2.5) expressa o balanço de massa no gasômetro G ,

$$x_t^G = x_{t-1}^G + (Fp_t^G - Fc_t^G - \sum_{j=1}^{N_{bo}} fc_{j,t}^{b,G} - \sum_{j=1}^{N_m} fc_{j,t}^{m,G}) \cdot T - S_{H,t}^G, \quad (2.5)$$

em que o nível do gasômetro calculado para o período t depende do nível no período anterior (em m^3), da vazão total prevista do gás G a ser gerada no período t (Fp_t^G em m^3/h), da vazão total prevista do gás G (Fc_t^G em m^3/h) a ser utilizada pelos consumidores não-controlados da planta industrial no período t , além das vazões para caldeiras,

misturadoras e torres de proteção.

A Equação (2.6) estabelece que a vazão total de um combustível particular admitido na fornalha da caldeira j é igual ao produto da capacidade máxima do queimador (U_j^F em m^3/h ou kg/h) pela quantidade calculada de queimadores acesos no período em questão ($N_{j,t}^F$). Deste resultado é descontada a quantidade não usada de cada queimador, a qual é representada por meio da variável de folga $sf_{j,t}^F$,

$$fc_{j,t}^{b,F} = U_j^F N_{j,t}^F - sf_{j,t}^F. \quad (2.6)$$

A Equação (2.7) permite a possibilidade de uso dos queimadores em faixas operacionais intermediárias. Nesta equação, C_{opr}^F é a faixa operacional dos queimadores que expressa a razão entre as capacidades máxima e mínima de liberação de calor de um queimador, sem risco de apagamento do queimador, cujo termo correspondente em inglês é *turn-down ratio (TDR)*, que pode variar entre 0 e 1,

$$sf_{j,t}^F \leq C_{opr}^F U_j^F N_{j,t}^F. \quad (2.7)$$

O balanço mássico de vapor nas caldeiras é expresso por meio da Equação (2.8). Nela, a vazão de vapor produzido na caldeira j ($f_{j,t}^{stm}$) é igual à soma da vazão de vapor destinada à turbina j ($f_{j,t}^{tb}$) com a parcela de vapor extraída da caldeira j que é destinada aos processos industriais ($f_{j,t}^{psa}$),

$$f_{j,t}^{stm} = f_{j,t}^{tb} + f_{j,t}^{psa}. \quad (2.8)$$

A extração de vapor de processo na termoelétrica pode ocorrer diretamente da caldeira ou da turbina. A Equação (2.9) estabelece que a vazão de vapor de processo extraída da termoelétrica j ($f_{j,t}^{ps}$) é igual à soma do vapor extraído da respectiva caldeira e da respectiva turbina ($f_{j,t}^{psb}$),

$$f_{j,t}^{ps} = f_{j,t}^{psa} + f_{j,t}^{psb}. \quad (2.9)$$

A Equação (2.10) estabelece uma condição de controle necessária para operação estável do sistema, pois numa caldeira aquatubular é preciso que seja mantida o equilíbrio entre a vazão de água de alimentação da caldeira ($f_{j,t}^{water}$) e a vazão de vapor produzido na caldeira,

$$f_{j,t}^{water} = f_{j,t}^{stm}. \quad (2.10)$$

A Equação (2.11) descreve o balanço energético nas caldeiras e a Equação (2.12) descreve a transformação da energia mecânica em energia elétrica nas turbinas,

$$\sum_F C_v^F \cdot fc_{j,t}^{b,F} = \frac{H_{j,t}^{stm} f_{j,t}^{stm} - H_{j,t}^{water} f_{j,t}^{water}}{\eta_j^B}, \quad (2.11)$$

$$pw_{j,t}^{gen} = f_{j,t}^{tb} (H_{j,t}^{stm} - H_{j,t}^{exh}) \eta_j^T - f_{j,t}^{psb} (H_{j,t}^{ext} - H_{j,t}^{exh}) \eta_j^{ext}. \quad (2.12)$$

Observe que energia fornecida pelos combustíveis nas fornalhas das caldeiras (lado

esquerdo da Equação (2.11)) é igual à energia recebida pelo conjunto água/vapor (lado direito da Equação (2.11)). O coeficiente de rendimento (η_j^B) é utilizado para apurar as perdas. Nesta equação, $H_{j,t}^{stm}$ e $H_{j,t}^{water}$ são as entalpias do vapor na saída da caldeira e da água de alimentação da caldeira, respectivamente, Cv^F é o poder calorífico inferior dos combustíveis, e $f_{j,t}^{b,F}$, $f_{j,t}^{stm}$ e $f_{j,t}^{water}$ são as vazões dos combustíveis para a caldeira, de vapor d'água produzido na caldeira e de água de abastecimento de caldeira.

A Equação (2.12) corresponde à aplicação direta da primeira lei da termodinâmica ao turbogerador. O conceito de eficiência é novamente utilizado, e η_j^T é o coeficiente que contabiliza o fluxo de energia que não é convertido em energia mecânica no eixo da turbina devido às perdas na turbina. A potência elétrica disponível ($pw_{j,t}^{gen}$) é uma função da vazão de vapor na entrada da turbina e das entalpias do vapor na entrada ($H_{j,t}^{stm}$), na extração ($H_{j,t}^{ext}$) e na saída ($H_{j,t}^{exh}$) da turbina, η_j^{ext} é o rendimento da extração de vapor de processo na turbina e $f_{j,t}^{psb}$ é a vazão de vapor de processo que é extraída da turbina para a usina.

As Equações (2.13) e (2.14) apresentam as restrições operacionais dos gasômetros, conforme Figura 2,

$$x_{LL}^G \leq x_t^G \leq x_{HH}^G \quad (2.13)$$

$$x_L^G - S_{L,t}^G \leq x_t^G \leq x_H^G + S_{H,t}^G. \quad (2.14)$$

A Equação (2.15) estabelece que a vazão total de vapor das caldeiras durante cada período deve ser superior à demanda da planta D_t^{ps} ,

$$\sum_{j=1}^{N_{bo}} f_{j,t}^{ps} \geq D_t^{ps}. \quad (2.15)$$

A Equação (2.16) estabelece que a energia total gerada nos turbogeradores deve ser maior ou igual que a energia requerida pela planta D_t^E ,

$$\sum_{j=1}^{N_T} pw_{j,t}^{gen} \geq D_t^E, \quad (2.16)$$

sendo a potência ativa dada em kW e a vazão de vapor em kg/h .

As Equações (2.17) a (2.19) estabelecem demais restrições dos equipamentos nas casas de força, nelas $f_{min,j}^{b,F}$ e $f_{max,j}^{b,F}$ são respectivamente as vazões de admissão mínima e máxima do combustível F na caldeira j ; $f_{min,j}^{stm}$ e $f_{max,j}^{stm}$ são respectivamente as vazões mínima e máxima de produção de vapor de processo em regime permanente na caldeira j e $f_{min,j}^{tb}$ e $f_{max,j}^{tb}$ são respectivamente as vazões mínima e máxima de vapor admitida pela turbina j :

$$f_{min,j}^{b,F} \leq f_{j,t}^{b,F} \leq f_{max,j}^{b,F}, \quad (2.17)$$

$$f_{min,j}^{stm} \leq f_{j,t}^{stm} \leq f_{max,j}^{stm}, \quad (2.18)$$

$$f_{min,j}^{tb} \leq f_{j,t}^{tb} \leq f_{max,j}^{tb}. \quad (2.19)$$

Equações lógicas e auxiliares foram necessárias, pois são responsáveis por ajustar adequadamente os valores das variáveis de controle, especialmente aquelas que dizem respeito ao número de queimadores de combustível que devem estar acesos durante um período de simulação. Portanto, as equações lógicas são responsáveis por estabelecer a conexão entre as diversas restrições apresentadas e a função objetivo, manipulando de maneira metódica as relações do sistema por meio do acendimento ou apagamento dos queimadores, de maneira a fazer com que a permutação ou não dos combustíveis possa manter a estabilidade do sistema como um todo. Logo, são as equações lógicas e auxiliares as expressões responsáveis por estabelecer, de forma direta ou indireta, as vazões dos combustíveis para as caldeiras e determinar o volume de vapor que é gerado, o que implica na quantidade de vapor destinada à produção de eletricidade e na quantidade de vapor a ser enviada aos processos da usina. Deste modo, controlando a parcela dos gases destinada às centrais termoelétricas, essas equações são também responsáveis por manter o controle volumétrico do gasômetro.

A Equação (2.20) determina o chaveamento (comutação dos queimadores), sendo que $\Delta N_{j,t}^F$ representa o total de queimadores do combustível F que devem ser acesos ou apagados simultaneamente na caldeira j no período t ,

$$\Delta N_{j,t}^F = ub_{j,t}^{F,1} + ub_{j,t}^{F,2} + \dots + ub_{j,t}^{F,N'_{bu}}. \quad (2.20)$$

Na Equação (2.21), as variáveis binárias $ibn_{j,t}^{F+,i}$ representam se i queimadores do combustível F deverão ser ligados numa caldeira j no período t , e as variáveis binárias $ibn_{j,t}^{F-,i}$ representam se i queimadores do mesmo combustível deverão ser desligados na mesma caldeira no mesmo período,

$$ub_{j,t}^{F,i} = ibn_{j,t}^{F+,i} + ibn_{j,t}^{F-,i}. \quad (2.21)$$

Na Equação (2.22), $N_{j,t}^F$ representa o número total de queimadores do combustível F acesos na caldeira j no período t ,

$$N_{j,t}^F - N_{j,t-1}^F = \sum_{i=1}^{N'_{bu}} (ibn_{j,t}^{F+,i} - ibn_{j,t}^{F-,i}). \quad (2.22)$$

As Equações (2.23) e (2.24) representam outras equações lógicas auxiliares,

$$ibn_{j,t}^{F+,1} \geq ibn_{j,t}^{F+,2} \geq \dots \geq ibn_{j,t}^{F+,N'_{bu}}, \quad (2.23)$$

$$ibn_{j,t}^{F-,1} \geq ibn_{j,t}^{F-,2} \geq \dots \geq ibn_{j,t}^{F-,N'_{bu}}. \quad (2.24)$$

As restrições de balanço de massa nas estações de mistura são determinadas nas Equações (2.25) e (2.26), em que $fp_{j,t}^m$ é a vazão de gás misto produzido na estação misturadora j no período t ; $fc_{j,t}^{m,G}$ é a vazão de gás $G = BFG, COG, LDG$ ou NG para estação de mistura j no período t ; fp_t^m é a vazão total de gás misto produzido em todas as N_m estações de mistura no período t ; $fc_t^{m,hsm}$ é a vazão de gás misto consumido no HSM no

período t ; $f c_{j,t}^{m,b}$ é a vazão de gás misto consumido na caldeira j das termoeletricas; N_{bo} é o número total de caldeiras; e $S_{M,t}$ é uma variável de folga que representa o excesso de gás misto produzido nas estações de mistura e que devem ser enviadas para as torres de queima para proteção do sistema,

$$f p_{j,t}^m = \sum_G f c_{j,t}^{m,G}, \quad (2.25)$$

$$f p_t^m = \sum_j^{N_m} f p_{j,t}^m = f c_t^{m,hsm} + \sum_j^{N_{bo}} f c_{j,t}^{m,b} + S_{M,t}. \quad (2.26)$$

Os poderes caloríficos $C v_j^G$ dos gases $G = \text{BFG}, \text{COG}, \text{LDG}$ e NG usados nas estações de mistura j satisfazem às Equações (2.27) e (2.28), sendo $C v_{min,j}^{MG}$ e $C v_{max,j}^{MG}$, respectivamente, os limites do poder calorífico inferior e superior do gás misto produzido na estação misturadora j ,

$$\sum_j^{N_m} \sum_G (C v_{min,j}^{MG} - C v_j^G) f c_{j,t}^{m,G} \leq 0, \quad (2.27)$$

$$\sum_j^{N_m} \sum_G (C v_j^G - C v_{max,j}^{MG}) f c_{j,t}^{m,G} \leq 0. \quad (2.28)$$

Outras restrições operacionais das estações de mistura são formuladas conforme equações (2.29), (2.30) e (2.31), nas quais $f c_{min,j}^{m,G}$ e $f c_{max,j}^{m,G}$ são as vazões mínima e máxima de cada gás para cada estação misturadora j , $f p_{min,j}^m$ e $f p_{max,j}^m$ são os limites de produção mínimo e máximo de gás misto em cada estação misturadora, e $f p_{max}^{MG}$ é a máxima vazão de gás misto que pode ser transportada no sistema de distribuição de gases,

$$f c_{min,j}^{m,G} \leq f c_{j,t}^{m,G} \leq f c_{max,j}^{m,G}, \quad (2.29)$$

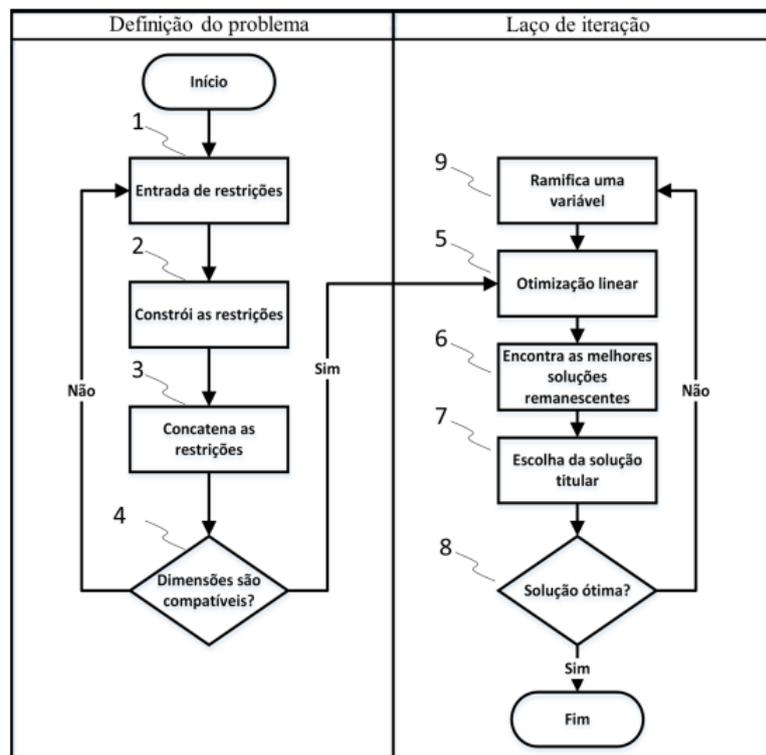
$$f p_{min,j}^m \leq f p_{j,t}^m \leq f p_{max,j}^m, \quad (2.30)$$

$$f p_t^m \leq f p_{max}^{MG}. \quad (2.31)$$

2.2 Implementação do Algoritmo de Otimização

O modelo MILP com 5 períodos de otimização de 12 minutos, que descreve a planta apresentada na Figura 1, possui 1290 variáveis e 1775 restrições. Esse modelo recebe as séries de previsão para próxima hora e informações sobre o estado do sistema, e resolve a Equação (2.1) sem violar as restrições apresentadas na seção anterior. Para resolver o problema de otimização, foi desenvolvido um algoritmo de ramificação e avaliação progressiva (ver Nemhauser e Wolsey (1999)) implementado por Pena (2013), cujo fluxograma resumido por Oliveira Júnior (2016) é apresentado na Figura 4. O modelo e o algoritmo de otimização foram desenvolvidos no *software MATLAB*[®]. O tempo médio de execução do algoritmo de otimização é 0,9 segundos num computador com processador *i7 7500U* de 2,9 GHz.

Figura 4: Fluxograma do algoritmo de ramificação e avaliação progressiva.



Fonte: Oliveira Júnior (2016).

Inicialmente, os Passos **1**, **2**, **3** e **4** são responsáveis pela definição e montagem do problema. No Passo **1** o modelo é formulado, isto é, são inseridas a função objetivo e as restrições do problema de planejamento da distribuição de gases. O Passo **2** é responsável por consolidar e uniformizar os formatos das equações, ou seja, garantir que todas as equações co-associem todas as variáveis de decisão, utilizando coeficientes nulos para as variáveis não relacionadas a uma dada restrição. No Passo **3**, é feito o encadeamento entre todas as equações do modelo MILP de forma a se obter uma estrutura única. O Passo **4** verifica se o problema está plenamente definido e se todas as equações foram devidamente uniformizadas, ou seja, se as dimensões da estrutura são compatíveis com o problema (número de variáveis, número de restrições etc).

Caso os dados estejam coerentes procede-se para o laço de iteração para, de fato, resolver o problema MILP. O laço de iteração, composto pelos Passos **5**, **6**, **7**, **8** e **9**, é responsável por encontrar a solução ótima para o problema MILP. O algoritmo começa por resolver o problema irrestrito (Passo **5**), isto é, sem as restrições inteiras e binárias. Esse resultado pode ser armazenado como uma solução remanescente, caso seja melhor que uma solução titular inicialmente ajustada (Passo **6**). A partir das soluções remanescentes, é feita a escolha da solução titular (Passo **7**), ou então é mantida a solução previamente definida. Uma solução titular é uma solução factível e que atenda a todas as restrições do problema, inclusive as restrições inteiras e binárias.

Na seqüência, verifica-se se a solução titular é ótima (Passo **8**), isto é, se não há no conjunto das soluções remanescentes alguma solução com custo menor. Caso não exista,

o programa é finalizado com sucesso. Caso contrário, a melhor das soluções remanescentes será ramificada (Passo 9) em dois novos problemas com uma nova restrição em cada: uma restrição do tipo menor ou igual e uma restrição do tipo maior ou igual. E, então retorna-se para o Passo 5 e o procedimento continua até que uma solução viável seja encontrada.

2.3 Sintonia dos parâmetros do Modelo MILP

Considerando que o processo de otimização seja implantado num sistema em tempo real e que um algoritmo de controle por horizonte rolante seja usado como estratégia de controle, é conveniente que a sintonia dos pesos do otimizador possa ser automatizada. Todavia, como explicado na revisão bibliográfica (ver Seção 1.1.2), os trabalhos anteriores não permitem que a sintonia seja feita automaticamente, pois os procedimentos anteriormente propostos exigem que, em alguma etapa, seja feito algum tipo de análise de sensibilidade.

A estratégia aqui proposta, por outro lado, tem como referência os trabalhos de sintonia automática dos parâmetros de algoritmos de controle preditivo do tipo MPC. Nesses algoritmos, os métodos não-automáticos de sintonia são aplicados apenas no modo *off-line*, normalmente, em etapas de pré-sintonia realizadas por procedimentos baseados em regras heurísticas. Mas métodos automáticos de sintonia são aplicados tanto na forma *off-line* quanto na forma *on-line*, quando os parâmetros são prontamente calculados se a qualidade da resposta se deteriora (ALMEIDA; SALLES, 2016).

Nesse caso, os métodos de sintonia automática dos parâmetros dos controladores preditivos, usados entre os níveis de controle regulatório e de otimização, requerem maior esforço computacional, pois necessitam de um algoritmo de otimização para escolha adequada de valores dos parâmetros que otimizam o desempenho do sistema (AL-GHAZZAWI et al., 2001), (PEREIRA et al., 2014) e (ALMEIDA; SALLES, 2016). Apesar disto, a sintonia automática é justificada visto que pode aumentar a produtividade e a segurança do sistema, pois se for detectado que os indicadores de desempenho do sistema estão ruins, a sintonia automática pode produzir ajustes que adaptam o sistema a um novo cenário de operação, e tudo isso sem a necessidade de intervenção humana.

A otimização dos parâmetros nos métodos automáticos, neste caso, pode ser realizada de duas maneiras:

- por algoritmos que calculam a derivada de uma função custo não-linear em relação aos parâmetros de sintonia (ALI; NOUH; ZAFIRIOU, 1993) e (ALMEIDA; SALLES, 2016). A heurística proposta em Oliveira, Pena e Salles (2016), de forma indireta, realiza esta operação;
- por algoritmos evolutivos, os quais tem sido aplicados com sucesso em problemas complexos (multi-objetivos com multi-variáveis e com restrições) cuja função

custo possui mínimos locais que dificultam a sintonia dos parâmetros próximos do mínimo global (GEN; CHENG; LIN, 2008) e (ALMEIDA; SALLES, 2016).

Nesta tese, a sintonia é feita *off-line*, mas pode facilmente ser aplicada *on-line*, e o algoritmo pode ser executado no modo automático. A opção foi pelo uso de uma técnica meta-heurística. Por meta-heurística, entende-se, segundo Hillier e Lieberman (2013), um método de resolução geral que fornece tanto uma estrutura quanto diretrizes de estratégia gerais para desenvolver um método heurístico específico, que se ajusta a um tipo de problema específico. Meta-heurísticas provavelmente encontram uma excelente solução viável, mas não necessariamente uma solução ótima, para um certo problema. Uma característica fundamental de uma meta-heurística é a forma como permite, durante a execução do algoritmo, a fuga dos ótimos locais e como executa uma busca consistente numa região de soluções viáveis.

Estas técnicas têm sido utilizadas com sucesso na resolução de problemas grandes, complexos, sofisticados, inclusive em diversos problemas de otimização combinatória. Nestes problemas, quando é difícil ou mesmo impossível encontrar uma solução ótima através de um método exato, ou mesmo quando o tempo para se encontrar uma solução ótima por meio de um método exato for crítico, métodos aproximados podem ser usados para encontrar uma solução boa, suficientemente próxima de um valor ótimo e em tempo relativamente ágil (GEN; CHENG; LIN, 2008) e (HILLIER; LIEBERMAN, 2013).

Dentre as meta-heurísticas, as que se baseiam em reproduzir computacionalmente características de seres vivos são aquelas que mais têm sido usadas para solucionar difíceis e complexos problemas de otimização, de acordo com Gen e Cheng (2000) e Gen, Cheng e Lin (2008). O termo em uso para se referir a tais técnicas é computação evolutiva. No caso específico, será apresentado o uso do algoritmo de otimização por enxame de partículas, que apresenta a possibilidade de ser usado numa rotina automática.

A otimização por enxame de partículas, do inglês *Particle Swarm Optimization* (PSO), é um método computacional de otimização que, de modo iterativo, induz a melhoria da solução de um problema mediante o progresso de uma partícula (solução) medido em relação a uma função de avaliação de desempenho (função *fitness*). Essa meta-heurística é baseada na simulação do comportamento do vôo de pássaros e, desta forma, seu algoritmo incorpora a idéia de aprendizado coletivo e desempenho individual, isto é, cada partícula (pássaro) ajusta a trajetória e a velocidade do seu vôo mediante comparação entre sua melhor solução (posição) já alcançada e a melhor resposta da partícula que alcançou melhor solução. Assim, a cada nova iteração, a tendência é que as partículas possam melhorar sua resposta de acordo com o conhecimento próprio e social (POLI, 2007).

Neste método, as partículas estão propensas a percorrer um amplo espaço de busca (solução), pois, sempre que houver uma nova solução global haverá uma nova oportunidade de outras partículas corrigirem sua direção de vôo para exploração do espaço de busca (local) em torno desta nova solução. Por causa destas características, a otimização por exame de partículas pode se revelar uma alternativa rápida em relação ao pro-

cedimento proposto em (OLIVEIRA; PENA; SALLES, 2016) e, portanto, interessante para avaliação dos parâmetros do modelo de otimização do sistema de distribuição de gases siderúrgicos.

2.3.1 Conceitos básicos

A otimização por enxame de partículas tem sido tão bem sucedida na resolução de problemas que, em pouco mais de uma década, centenas de artigos relatam aplicações científicas e industriais (POLI, 2007). Essa técnica foi inicialmente proposta pelo psicólogo James Kennedy e pelo engenheiro eletricitista Russell Eberhart (KENNEDY; EBERHART, 1995), os quais se basearam nas simulações computacionais do movimento de bandos de pássaros ((REYNOLDS, 1987); (HEPPNER; GRENANDER, 1990)) ou cardumes de peixes (WILSON, 1987).

2.3.2 Descrição do algoritmo PSO

O PSO possui muitas semelhanças como os algoritmos genéticos. Deste modo, o sistema é iniciado com uma população de soluções aleatórias e procura por soluções ótimas atualizando essa população. Contudo, diferente dos algoritmos genéticos, não possui operadores de evolução, tais como cruzamento e mutação. Em vez disso, segundo Kendall e Su (2005), o vôo de cada partícula é controlado de acordo com uma velocidade também aleatória que ajusta o vôo sobre o espaço de soluções seguindo as partículas ótimas atuais, ou seja, as melhores partículas. De acordo com Poli (2007), esse é um jeito de encontrar uma nova forma de inteligência artificial, a inteligência coletiva (*swarm intelligence*).

Cada partícula mantém as coordenadas da melhor solução (*fitness* - índice de desempenho) que ela tenha alcançado. O valor do *fitness* é também armazenado. Esse valor é chamado de pbest. A otimização por enxame de partículas armazena além do pbest, o gbest que é a melhor solução (posição) para o problema até a iteração atual. O gbest está associado ao melhor resultado entre todos os *fitness* obtidos por todas as partículas da população. O princípio dessa meta-heurística consiste em fazer com que a cada iteração, as partículas ajustem suas velocidades de modo a investigar novas soluções entre a atual posição da partícula e a posição da melhor partícula, ou ainda nas redondezas da melhor partícula. Isto é, as partículas procuram por posições que minimizem um índice de desempenho ((KENNEDY; EBERHART, 2001); (CLERC; KENNEDY, 2002)).

De acordo com Poli (2007), se o problema for N-dimensional, a posição de cada partícula e sua velocidade podem ser representados por meio de vetores com N componentes (um para cada dimensão). Começando pelo vetor velocidade, $v = (v_1, \dots, v_N)$, cada componente v_i é dada pela Equação (2.32):

$$v_i(t+1) = \omega v_i(t) + \psi_1 R_1(x_{s_i} - x_i(t)) + \psi_2 R_2(x_{p_i} - x_i(t)). \quad (2.32)$$

Sendo que x_{s_i} é o i-ésimo componente da melhor posição alcançada por alguma partícula do bando, $x_i(t)$ é a i-ésima componente de posição da partícula, x_{p_i} é a i-ésima

melhor componente de posição da partícula, R_1 e R_2 são variáveis independentes aleatórias com distribuição uniforme em $[0,1]$, ω é uma constante conhecida como coeficiente de inércia (SHI; EBERHART, 1999), e ψ_1 e ψ_2 são os coeficientes de aceleração responsáveis, respectivamente, pela introdução do ajuste social e cognitivo.

A posição da partícula i no instante t é ajustada por meio da Equação (2.33):

$$x_i(t+1) = x_i(t) + v_i(t+1). \quad (2.33)$$

A próxima iteração ocorre após todas as partículas terem se movido. Em alguns problemas, para se evitar que ocorra uma convergência prematura para um mínimo local, a equação de velocidade é corrigida por uma constante de constrição (κ) segundo formulação desenvolvida por Clerc e Kennedy (2002).

Segundo Poli (2007), a Equação (2.34) é amplamente usada, e, quando ψ_1 , ψ_2 , κ (ou ω) são adequadamente escolhidos, então o PSO tem garantia de estabilidade sem necessidades especiais de restrições (isto é, limitações de velocidade e posições). Para maiores detalhes acerca desta metodologia, seja do ponto de vista teórico ou do algoritmo, veja Poli (2007); Poli, Kennedy e Blackwell (2007),

$$v_i(t+1) = \kappa(v_i(t) + \psi_1 R_1(x_{s_i} - x_i(t)) + \psi_2 R_2(x_{p_i} - x_i(t))). \quad (2.34)$$

A escolha dos valores do PSO se dá através de tentativa-e-erro (POLI; KENNEDY; BLACKWELL, 2007) através de um certo número de experimentos, pois depende da natureza do problema. Com respeito ao tamanho da população inicial, em alguns problemas, 10 partículas são suficientes, em outros mais difíceis pode-se tentar entre 100 e 200 indivíduos. ψ_1 e ψ_2 usualmente são iguais a 2. Contudo, podem variar no intervalo $[0,4]$. Como critério de parada, uma alternativa é usar algum artifício elaborado a partir da convergência da população, da determinação de um número máximo de iterações ou limitação do tempo de processamento.

Nesta tese, a posição de cada partícula possui 16 dimensões que estão associadas aos 16 pesos referentes aos custos operacionais dos gasômetros e dos queimadores (ver Tabela 15). O objetivo do PSO é diminuir a soma dos indicadores de desempenho apresentados na próxima seção. Esses indicadores são úteis para sintonia dos parâmetros do modelo MILP (com 5 períodos de 12 minutos cada) usado pelo algoritmo de controle por horizonte rolante, que neste caso, foi simulado com horizonte de planejamento igual a 24 horas, horizonte de controle igual a 1 e previsão perfeita com horizonte de previsão igual a 60 minutos. Neste caso, em cada iteração, quando foi realizada a rolagem do algoritmo de controle, um conjunto com previsões para os próximos 60 minutos era usado. As iterações ocorreram até que o horizonte de planejamento fosse atingido. Foram avaliadas populações com 40, 50 e 60 indivíduos. A convergência foi investigada mediante simulações com 75, 100 e 150 iterações como critério de parada. O fator de inércia, a componente cognitiva e o componente social foram ajustados com o valor empírico igual a 0,5. O tempo de simulação, no caso, com 100 iterações e 50 indivíduos, foi de aproximadamente 6,25 dias. Para maiores detalhes, verificar Capítulo 4.

2.3.3 Indicadores de desempenho

Para se medir a qualidade da sintonia do modelo, em Oliveira, Pena e Salles (2016) foram apresentados cinco indicadores de desempenho. Esses índices são: o ABS que mede as comutações dos queimadores (*Average burner's switching (sw/h)*), o AEP que mede a potência elétrica ativa (*Average electric power (MW)*), o DGHL que mede o desvio de nível do gasômetro (*Deviation of the gas holder level (dam³)*), o ELFS que mede a perda de energia em torres de queima (*Energy losses in the flare stack (GJ/h)*), e o UTAR que mede o uso de alcatrão (*Use of TAR (t/h)*). As fórmulas destes índices são apresentadas, respectivamente, pelas Equações (2.35) a (2.39):

$$ABS = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_{j=1}^{N_{bo}} \sum_F \Delta N_{j,t,k}^F}{h_s}; \quad (2.35)$$

$$AEP = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_{j=1}^{N_T} pw_{j,t,k}^{gen}}{h_s}; \quad (2.36)$$

$$DGHL = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_G |x_{t,k}^G - x_N^G|}{h_s}; \quad (2.37)$$

$$ELFS = 10^{-3} \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_G (\frac{C_p^G}{C_p^{COG}}) S_{H,t,k}^G}{h_s}; \quad (2.38)$$

$$UTAR = 10^{-3} \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_{j=1}^{N_{bo}} f_{j,t}^{b,TAR}}{h_s}. \quad (2.39)$$

No entanto, esses índices não estão normalizados. Por essa razão, Oliveira, Pena e Salles (2016) utilizaram artifícios (ponderações) para minimizar o impacto de alguns índices como o *ELFS* (ver Equação (2.38)) e o *UTAR* (ver Equação (2.39)); além disso, cada um dos índices possui uma unidade de medida diferente das unidades dos demais. Apesar disso, o emprego desses índices foi bem sucedido para a finalidade do artigo citado, uma vez que no decorrer do procedimento ali relatado esses índices foram avaliados, na seqüência, por técnicas de análise de sensibilidade. Outro ponto que pode gerar confusão é que enquanto os índices *ABS*, *DGHL*, *ELFS* e *UTAR* idealmente devem ser nulos, o índice *AEP* deve ser máximo.

Nesta tese, esses índices compõem a função de avaliação usada para sintonizar os pesos dos parâmetros do modelo de otimização usada pelo algoritmo de controle por horizonte rolante e, por essa razão, é importante que esses índices sejam adimensionais e estejam normalizados para que sejam equivalentes (em módulo) entre si (ver Equação (2.45)). Portanto, os índices apresentados foram normalizados como expresso nas Equações (2.40) a (2.44). Observa-se agora que cada um dos índices assume valores entre 0 e 1. Nota-se também que o índice AEP_N , assim como os demais, deve ser idealmente nulo e mede a potência ativa não-gerada. Em síntese, os índices normalizados são:

(a) o número normalizado de comutação dos queimadores (ABS_N):

$$ABS_N = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_{j=1}^{N_{bo}} \sum_F \Delta N_{j,t,k}^F}{h_s \sum_{j=1}^{N_{bo}} \sum_F N'_{bu,F}}. \quad (2.40)$$

(b) a potência ativa normalizada não-gerada nos geradores (AEP_N):

$$AEP_N = 1 - \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_{j=1}^{N_T} pw_{j,t,k}^{gen}}{h_s \sum_{j=1}^{N_T} pw_{j,max}^{gen}}. \quad (2.41)$$

(c) o desvio normalizado do nível de referência dos gasômetros ($DGHL_N$):

$$DGHL_N = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_G |x_{t,k}^G - x_N^G|}{h_s \sum_G x_N^G}. \quad (2.42)$$

(d) a queima normalizada de combustível gasoso nas torres de proteção ($ELFS_N$):

$$ELFS_N = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_G \left(\frac{C_p^G}{C_{pCOG}^G}\right) S_{H,t,k}^G}{h_s \sum_G (x_{HH}^G - x_N^G)} + \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_i^{N_M} \left(\frac{C_p^{MG}}{C_{pCOG}^G}\right) S_{M,t,k}^i}{h_s \sum_j^{N_{bo}} f c_{max,j}^{m,b} T}. \quad (2.43)$$

(e) o consumo normalizado de alcatrão nas termoelétricas ($UTAR_N$):

$$UTAR_N = \frac{\sum_{k=0}^{t_{it}-1} \sum_{t=1}^{h_c} \sum_{j=1}^{N_{bo}} f c_{j,t}^{b,TAR}}{h_s \sum_{j=1}^{N_{bo}} f c_{max,j,t}^{b,TAR}}. \quad (2.44)$$

A função *fitness* avaliada pelo PSO tem como objetivo minimizar a soma dos índices normalizados ABS_N , AEP_N , $DGHL_N$, $ELFS_N$ e $UTAR_N$, isto é, minimizar a Equação (2.45). No estudo cujos resultados estão na Seção 4.2, o horizonte de planejamento usado na simulação é igual a 24 horas,

$$FIT_{PSO} = ABS_N + AEP_N + DGHL_N + ELFS_N + UTAR_N. \quad (2.45)$$

Comentários sobre as relações entre os pesos e os índices:

(A) Quanto maior o peso W_{sw}^F , menor será o índice ABS_N , piores serão os índices AEP_N e $DGHL_N$ e possivelmente piores serão os índices $ELFS_N$ e $UTAR_N$. Isso ocorre porque o aumento do custo de comutação dos queimadores nas termoelétricas diminui naturalmente o número de comutações e portanto diminui a velocidade da casa de força em adequar o *mix* do consumo de combustível nas caldeiras.

- Assim, o aumento da produção de gás poderia não resultar no aumento da geração elétrica.
- Como consequência, poderá ocorrer o aumento do nível do gasômetro cujo gás está aumentando a produção, ou a diminuição do nível do gasômetro cujo gás está diminuindo a produção.
- Deste modo, o aumento do nível do gasômetro cujo gás está aumentando a produção pode resultar na queima de gás na torre de proteção.

- A diminuição do número de comutações poderia promover o aumento no consumo de alcatrão, se houvesse algum queimador de alcatrão aceso, ele tenderia a ficar aceso por longo período de tempo.

(B) Quanto maiores os pesos W_H^G , W_L^G , $W_{d^+}^G$ e $W_{d^-}^G$, menor será o índice $DGHL_N$, piores serão os índices ABS_N e AEP_N e possivelmente piores serão os índices $ELFS_N$ e $UTAR_N$. Isso ocorre porque uma elevada penalidade para desvios em relação ao valor de referência força o gasômetro a trabalhar próximo ao valor visado (normal) de operação.

- Como consequência, haverá maior comutação dos queimadores nas termoeletricas para que as casas de força absorvam mais rapidamente as flutuações das vazões de gás.
- Outra consequência do gasômetro manter seu nível próximo ao valor de referência é a diminuição da geração elétrica. Pois, a parcela de gás que poderia gerar eletricidade num momento mas está armazenada, pode ser queimada nas torres de proteção num momento posterior se o nível subir abruptamente e o tempo não for suficiente para as termoeletricas absorverem essa parcela.
- Uma elevada penalidade para desvios em relação ao valor de referência força o gasômetro a trabalhar próximo ao valor visado (normal) de operação. Em situações extremas, o sistema poderia ser forçado a queimar gás num período, ao invés de permitir o gasômetro operar acima do valor de referência em períodos posteriores.
- Em situações extremas, o sistema poderia ser forçado a usar alcatrão para suprir a demanda de energia, ao invés de permitir o gasômetro operar abaixo do valor de referência.

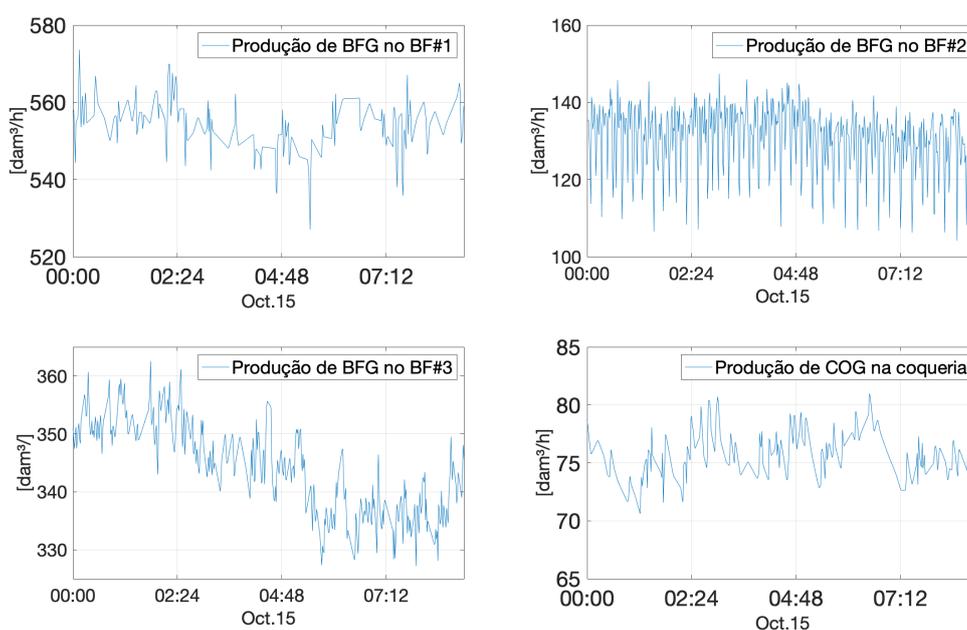
Ou seja, a sintonia dos pesos W_H^G , W_L^G , $W_{d^+}^G$, $W_{d^-}^G$ e W_{sw}^F é imprescindível para a harmonia operacional dos gasômetros e das caldeiras, apontando o ponto de equilíbrio entre o armazenamento dinâmico de gás no gasômetro e o aumento ou diminuição do uso do mesmo nas casas de força. Conseqüentemente, isto impacta os índices que medem: o número normalizado de comutação dos queimadores, a potência ativa normalizada não-gerada nos geradores, o desvio normalizado do nível de referência dos gasômetros, a queima normalizada de combustível gasoso nas torres de proteção e o consumo normalizado de alcatrão nas termoeletricas.

3 Modelos de Previsão

Nesta tese, primeiramente foram realizadas análises das características individuais de cada uma das séries de produção e consumo dos gases citados. Depois, foi definido qual procedimento de previsão deveria ser usado para previsão de cada uma das séries dos gases BFG, COG e LDG, além da série do gás misto e também das séries de demanda de eletricidade e consumo de vapor de processo pela planta siderúrgica. As previsões da produção total e do consumo total não-controlado de gases foram determinadas adicionando-se, respectivamente, as previsões de produção individual e de consumo individual não-controlado.

Análises das características das séries sugerem que os parâmetros dos modelos das séries temporais lineares devem ser estimados periodicamente, isto é, a cada deslizamento da janela de dados móvel. Isto porque as características de produção e consumo mudam bastante. Essas características ficam evidentes após observação das séries de produção dos gases BFG e COG (ver Figura 5) e LDG (ver Figura 6); das séries de consumo de BFG nos altos-fornos e na coqueria (ver Figura 7); das séries de consumo de COG nos altos-fornos e na coqueria (ver Figura 8) e demandas de BFG, LDG, MG e vapor de processo (ver Figura 9), além da demanda de eletricidade (ver Figura 10).

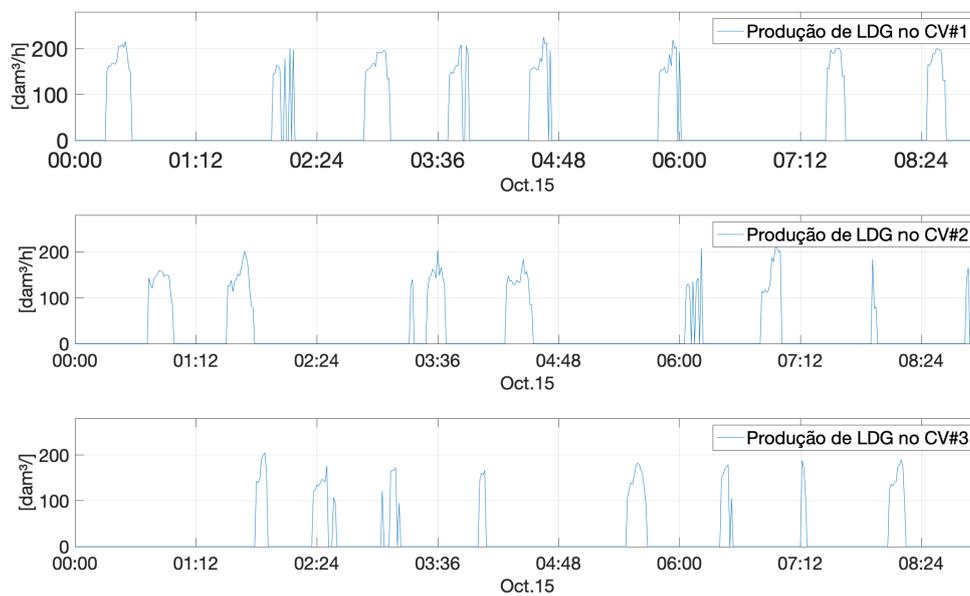
Figura 5: Trechos originais das séries de produção de BFG e COG.



Fonte: elaboração própria.

A previsão das séries temporais sazonais é feita pelo Método de Suavização Exponencial Sazonal proposto por Holt & Winters (veja Seção 3.2), porque é mais fácil de ser implementado e requer menor capacidade computacional do que o método Box & Jenkins com sazonalidade (SARIMA)(ver Box et al. (2015) e Rossi e Brunelli (2015)). As séries temporais sem sazonalidade são modeladas pelo Modelo Auto-Regressivo Integrado de Média Móvel (ARIMA) (veja Seção 3.3), pois este permite modelar séries temporais lineares genéricas que não podem ser representadas pelos modelos de suavização exponencial propostos por Holt e Brown (ZHU et al., 2015), apesar de ter um custo computacional maior.

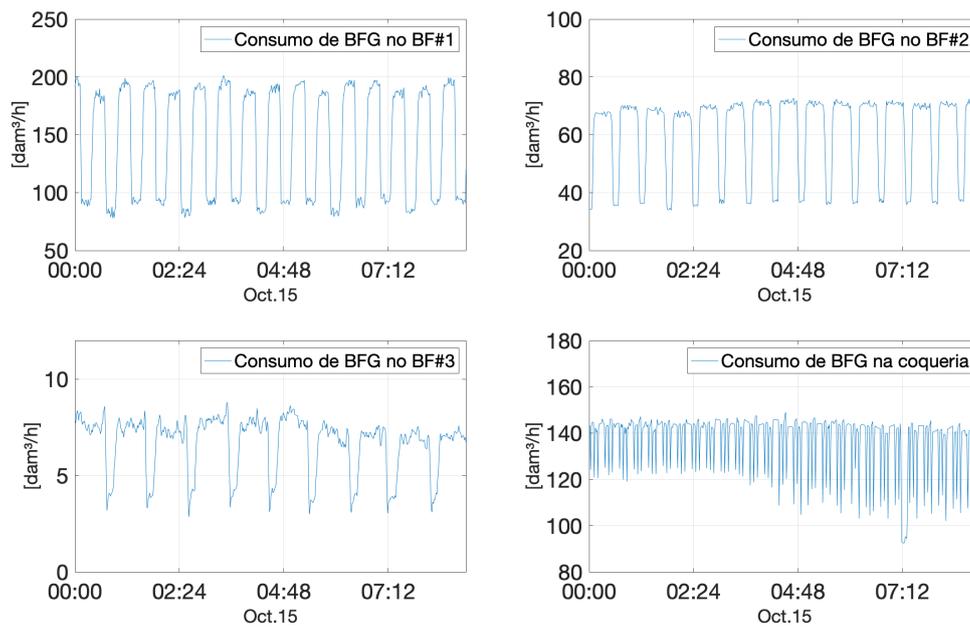
Figura 6: Trechos originais das séries de produção de LDG.



Fonte: elaboração própria.

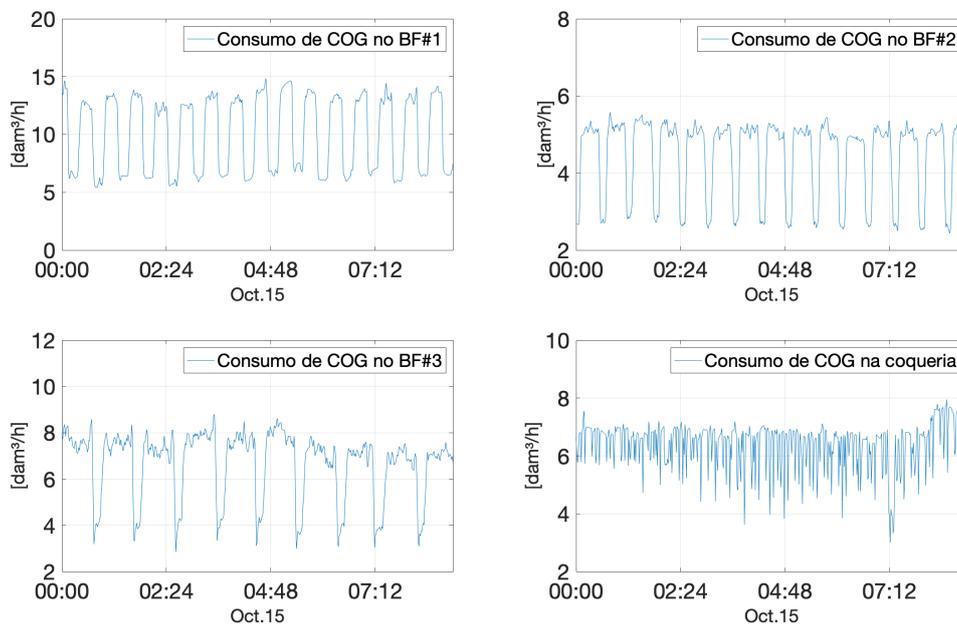
Porém, nem todas as séries temporais presentes no sistema de distribuição de gás estudado neste trabalho podem ser adequadamente modeladas por meio dos métodos de Holt-Winters ou Box & Jenkins. Por essa razão, na Seção 3.4 é proposto um método heurístico, para previsão da produção de LDG, que leva em consideração a programação de sopro de oxigênio nos convertedores da aciaria; e, na Seção 3.5 é visto que o método da média móvel é mais eficiente (ou seja, é mais simples de implementar, tem menor custo computacional e menor erro de previsão) para previsões da série de vapor de processo a ser extraído nas caldeiras e turbinas e da série de BFG a ser consumido no PCI.

Figura 7: Trechos originais das séries de consumo de BFG nos altos-fornos e coqueria.



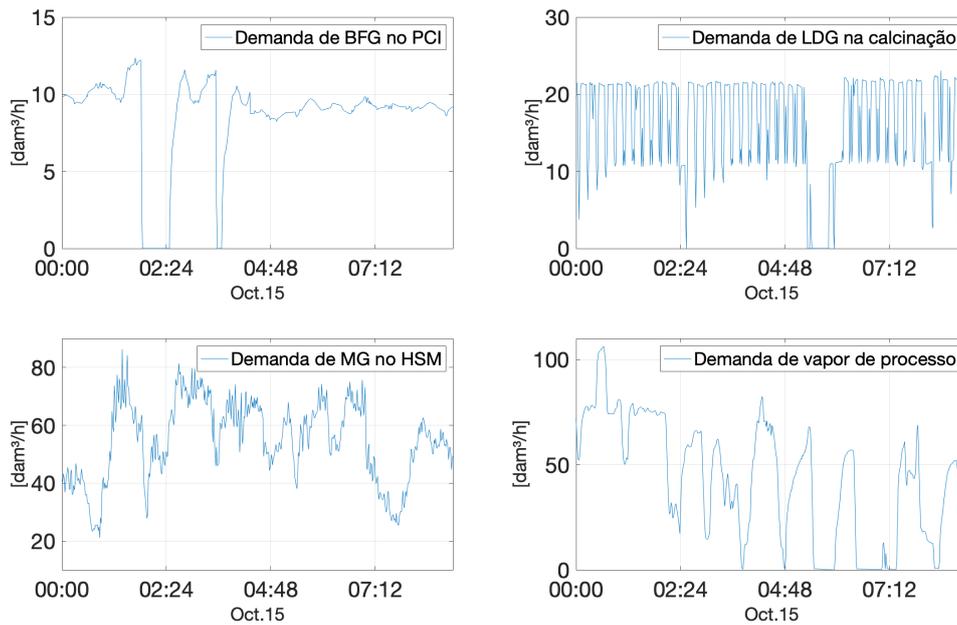
Fonte: elaboração própria.

Figura 8: Trechos originais das séries de consumo de COG nos altos-fornos e coqueria.



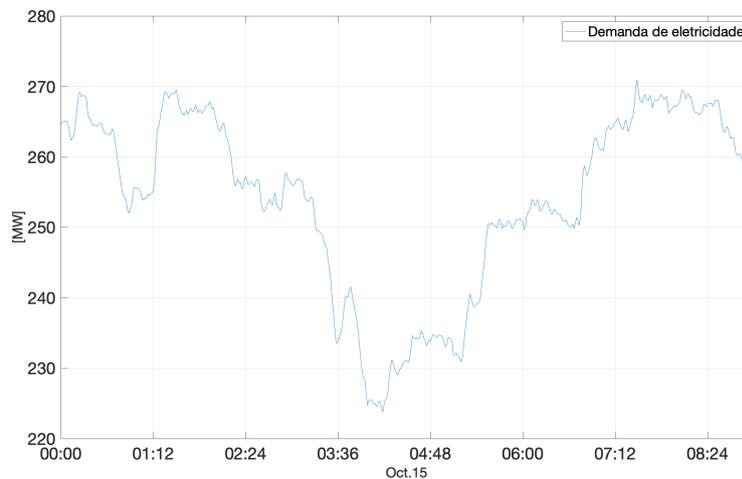
Fonte: elaboração própria.

Figura 9: Trechos originais das séries de demanda de gases e vapor de processo.



Fonte: elaboração própria.

Figura 10: Trecho original da série de demanda de eletricidade.



Fonte: elaboração própria.

A Tabela 2 apresenta os modelos usados na previsão das séries temporais desta tese. Observa-se que é proposto o uso do Método de Suavização Exponencial Sazonal para previsão da maioria das séries de consumo de gás não-controlado; é proposto o uso do Modelo Auto-Regressivo Integrado de Média Móvel na previsão dos produtores de BFG e COG, e para previsão da demanda de eletricidade e consumo controlado de gás MG pelo HSM; e, também um Modelo de Média Móvel para previsão do consumo não-controlado de BFG pelo PCI, LDG na calcinação e vapor de processo pela planta. Além disso, foi necessária a proposição de um procedimento heurístico para previsão da produção de LDG.

Tabela 2: Modelo das séries temporais usadas no algoritmo proposto.

Modelo de Séries Temporais	Processo
Holt-Winters com parâmetros adaptativos	BFG e COG consumido nos altos-fornos e na coqueria.
ARIMA com parâmetros adaptativos	Produção de BFG nos altos-fornos e de COG na coqueria, consumo de MG no processo HSM e demanda de eletricidade.
Procedimento Heurístico	Produção de LDG nos convertedores.
Procedimento de Média Móvel	Consumo de BFG no PCI e LDG na calcinação e extração de vapor de processo nas caldeiras e turbinas.

Fonte: elaboração própria.

Os algoritmos de previsão, que serão apresentados na seqüência, foram implementados no *software MATLAB*[®] e executados num computador com processador *i7 7500U* de 2,9 GHz. Os dados usados nesta tese foram fornecidos pela ArcelorMittal Tubarão, siderúrgica situada no estado do Espírito Santo, Brasil. Como o horizonte de planejamento usado na avaliação de desempenho do algoritmo de controle por horizonte rolante é igual a 24 horas, foram usados 33 horas de dados históricos para previsão das séries de produção de LDG e 32 horas para previsões das demais séries temporais. Conforme ocorre o deslizamento da janela de dados, são usadas 8 horas de dados passados para previsão das séries temporais, mas no caso da produção de LDG é usado o histórico das últimas 8 horas de programação de sopro de oxigênio e mais a programação de sopro na próxima hora, portanto, na simulação de 24 horas, são usados $8+24+1 = 33$ horas de dados. O tempo de amostragem na coleta dos dados é igual a 1 minuto.

Durante a pesquisa, foram testados históricos de dados entre 1 e 10 horas na previsão. No entanto, os menores erros de previsão ocorreram quando foram usados 8 horas de dados. Em algumas séries de previsão, os resultados obtidos com 6 horas de dados históricos foram próximos aos resultados obtidos com 8 horas. Porém, para uniformizar o procedimento com as demais séries, foi decidido pelo uso de 8 horas em todas as previsões, isso não prejudicou o desempenho do sistema nem aumentou o erro de previsão.

A Tabela 3 mostra os tempos médios de processamento (em segundos) dos métodos: HW (aqui denotado como \bar{T}_{HW}), ARIMA (p,d,q) (aqui denotado como \bar{T}_{ARIMA}) e pelo método heurístico (aqui denotado como \bar{T}_{HE}) para a produção dos gases BFG, COG e LDG e para o consumo não-controlado dos gases BFG e COG.

A Tabela 4 mostra os tempos médios de processamento (em segundos) dos métodos: ARIMA (p,d,q) (aqui denotado como \bar{T}_{ARIMA}) para a demanda de MG no processo HSM e eletricidade na planta industrial, e de Média Móvel (aqui denotado como \bar{T}_{MM}) no consumo de BFG no PCI, LDG na calcinação e extração de vapor de processo para planta industrial.

Tabela 3: Tempo Médio de Processamento(s) dos métodos de previsão HW, ARIMA e Heurístico em segundos.

Unidade	$\bar{T}_{HW}^{BFG}(s)$	$\bar{T}_{HW}^{COG}(s)$	$\bar{T}_{ARIMA}^{BFG}(s)$	$\bar{T}_{ARIMA}^{COG}(s)$	$\bar{T}_{HE}^{LDG}(s)$
BF#1	2,6	2,9	1,2	-	-
BF#2	2,6	3,0	2,7	-	-
BF#3	2,3	3,1	0,7	-	-
CO	3,8	3,7	-	0,9	-
CV#1	-	-	-	-	0,005
CV#2	-	-	-	-	0,005
CV#3	-	-	-	-	0,005
Total	11,3	12,7	4,6	0,9	0,015

Fonte: elaboração própria.

Tabela 4: Tempo Médio de Processamento(s) dos métodos de previsão ARIMA e Média Móvel em segundos.

Unidade	$\bar{T}_{ARIMA}^{MG}(s)$	$\bar{T}_{ARIMA}^{DE}(s)$	$\bar{T}_{MA}^{BFG}(s)$	$\bar{T}_{MA}^{LDG}(s)$	$\bar{T}_{MA}^{Dps}(s)$
HSM	0,50	-	-	-	-
Planta	-	1,60	-	-	-
PCI	-	-	0,002	-	-
Calcinação	-	-	-	0,002	-
Planta	-	-	-	-	0,002

Fonte: elaboração própria.

A Tabela 5 apresenta o tempo médio total de processamento (em segundos) das previsões e sintetiza os tempos médios para execução dos modelos de previsão.

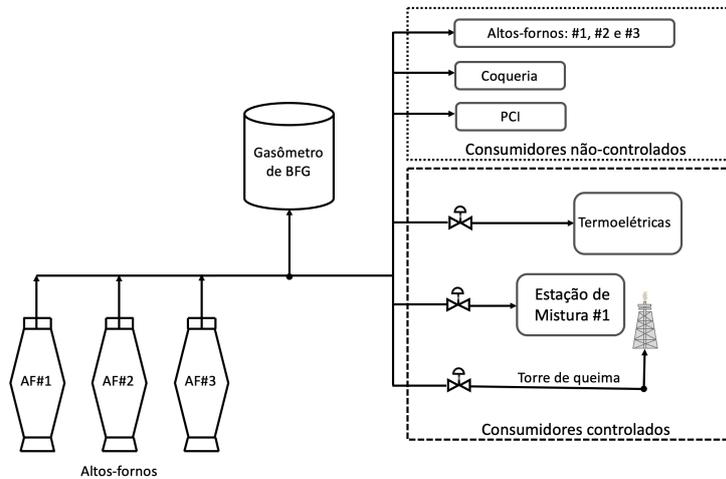
Tabela 5: Tempo médio para execução dos modelos de previsão em segundos.

Série Temporal	Tempo (s)
Produção Total de BFG	4,600
Produção Total de COG	0,900
Produção Total de LDG	0,015
Consumo Total de BFG	11,302
Consumo Total de COG	12,700
Consumo Total de LDG	0,002
Consumo Total de MG	0,500
Demanda de Eletricidade	1,600
Demanda de Vapor de processo	0,002
Tempo médio total de processamento	31,621

Fonte: elaboração própria.

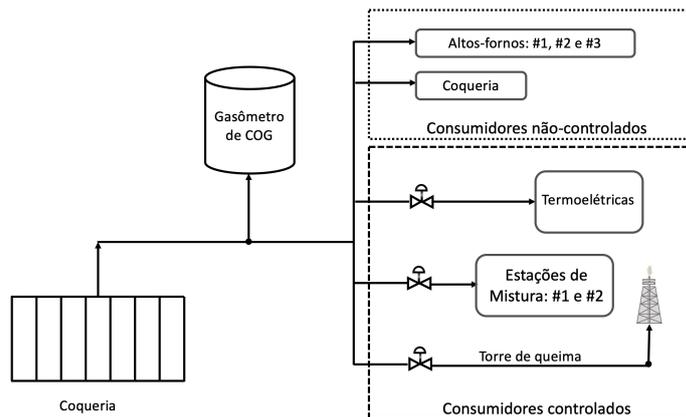
As Figuras 11 e 12 mostram as redes de distribuição dos gases BFG e COG, nesta seqüência, na planta.

Figura 11: Rede de distribuição de BFG.



Fonte: elaboração própria.

Figura 12: Rede de distribuição de COG.



Fonte: elaboração própria.

Os três produtores do gás BFG são os três alto-fornos (BF#1, BF#2 e BF#3) com as seguintes percentagens na produção total: 48%, 16% e 36%, respectivamente. O gás COG é completamente produzido nas baterias da coqueria (CO). Os principais consumidores não-controlados de gases BFG e COG são os três altos-fornos citados, a coqueria e o PCI, segundo percentagem apresentada na Tabela 6. O processo PCI consome apenas o gás BFG.

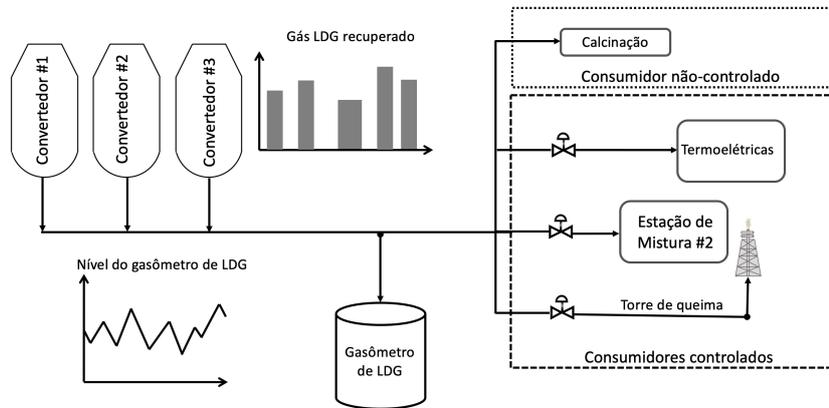
A Figura 13 mostra a rede de distribuição do gás LDG. A produção de LDG ocorre em batelada quando o oxigênio é injetado no convertedor (convertedores #1, #2 e #3). O gás LDG é totalmente consumido nas termoelétricas e nas estações de mistura. Observa-se que na rede de distribuição de LDG há apenas consumidores controlados, isto ocorre principalmente em razão da característica de produção intermitente.

Tabela 6: Distribuição dos consumidores não-controlados de BFG e COG.

Consumidores	COG	BFG
BF#1	35,7%	32,0%
BF#2	14,2%	12,8%
BF#3	22,8%	25,7%
CO	27,3%	27,6%
PCI	–	1,9%

Fonte: elaboração própria.

Figura 13: Rede de distribuição de LDG.



Fonte: elaboração própria.

3.1 Definições gerais

Seja definido por $\hat{Z}_{t+k\Delta T}$ a previsão k -passos-à frente de Z_t . Para simplificação, será substituído $\hat{Z}_{t+k\Delta T}$ por $\hat{Z}_t(k)$. Para avaliar os efeitos da previsão de k -passos-à frente na solução do algoritmo de horizonte rolante, é definido o erro percentual absoluto médio (MAPE - *mean absolute percentage error*) da seguinte forma:

$$\text{MAPE}(t) = 100 \sum_{k=1}^{h'_f} \frac{\epsilon(k)}{h'_f}, \quad (3.1)$$

sendo h'_f o horizonte de previsão re-amostrado dado por $h'_f = h_f \frac{T}{\Delta T} = 60$ e $\epsilon_t(k)$ o erro relativo à previsão k -passos-à frente de Z_t dado por:

$$\epsilon_t(k) = \left| 1 - \frac{\hat{Z}_t(k)}{Z_{t+k}} \right|, \quad (3.2)$$

sendo Z_{t+k} o valor da série temporal no instante $t + k\Delta T$.

O desempenho dos modelos de previsão propostos nesta seção será determinado a partir da média do índice MAPE(t) de acordo com a seguinte expressão:

$$\overline{\text{MAPE}} = \sum_{t=1}^N \frac{\text{MAPE}(t)}{N}, \quad (3.3)$$

em que $N = 10560$ amostras (1 semana) é a cardinalidade dos dados históricos de validação. O uso do \overline{MAPE} é interessante para quantificar o erro de previsão da série temporal em relação ao seu valor real. Assim, esse índice pode avaliar melhor o impacto do erro de previsão nas soluções do algoritmo de controle, em comparação com os índices: do erro absoluto médio (MAE - *mean absolute error*), do erro médio quadrático (MSE - *mean squared error*) e da raiz do erro médio quadrático (RMSE - *root-mean-square error*).

É importante ressaltar que o tempo de amostragem ΔT deve ter duração suficiente para permitir que os modelos de previsão capturem os detalhes do sinal medido, como sazonalidade nas séries de consumo dos gases BFG e COG e variações abruptas na produção de LDG. Neste estudo, o tamanho da janela móvel é de $n = 480$ amostras (que equivalem a 8 horas), e utiliza-se $\Delta T = 1$ min e $T = 12$ min.

3.2 Modelo de Previsão Holt-Winters

Em geral, a ideia de que observações passadas contém informações sobre o padrão de comportamento numa série temporal é a base dos métodos de previsão. Deste modo, o papel dos métodos de previsão é distinguir o padrão do sinal aleatório que possa estar contido nas observações, e então usar esse padrão para prever valores futuros da série.

Em geral, as principais vantagens das técnicas de suavização exponencial são simplicidade, boa precisão e eficiência computacional. A maior dificuldade destas técnicas ocorre na determinação dos valores mais apropriados das constantes de suavização. Para resolver esse problema, foi desenvolvido um algoritmo genético.

Neste trabalho, as séries temporais sazonais, como as de consumo de BFG nos altos-fornos e COG na coqueria, são modeladas pelo método aditivo de Holt-Winters (HW) (MONTGOMERY; JENNINGS; KULAHCI, 2008). HW é uma técnica de suavização exponencial que decompõe a série temporal sazonal Z_t em componentes de nível (μ_t), de tendência (T_t) e de sazonalidade (S_t), isto é,

$$Z_t = \mu_t + T_t + S_t + a_t, \quad (3.4)$$

sendo a_t um ruído branco com média zero. O método HW estima o nível, a tendência e os componentes sazonais de Z_t de acordo com as seguintes equações recursivas:

$$\bar{\mu}_t = \alpha(Z_t - \bar{S}_{t-s}) + (1 - \alpha)(\bar{\mu}_{t-1} + \bar{T}_{t-1}), \quad 0 < \alpha < 1, \quad (3.5)$$

$$\bar{T}_t = \beta(\bar{\mu}_t - \bar{\mu}_{t-1}) + (1 - \beta)\bar{T}_{t-1}, \quad 0 < \beta < 1, \quad (3.6)$$

$$\bar{S}_t = \gamma(Z_t - \bar{\mu}_t) + (1 - \gamma)\bar{S}_{t-s}, \quad 0 < \gamma < 1, \quad (3.7)$$

em que α , β e γ são constantes de suavização, e s é o período sazonal de Z_t . A previsão k -passos-à frente de Z_t é dada por:

$$\hat{Z}_t(k) = \bar{\mu}_t + k \bar{T}_t + \bar{S}_{t+k-hs}, \quad h = 1 + \text{int}(k/s), \quad (3.8)$$

sendo $\text{int}(\cdot)$ a parte inteira do argumento.

Devido às não linearidades, as constantes de suavização e o período sazonal podem mudar ao longo do tempo, sendo necessário reestimá-los a cada intervalo de tempo $h_c \cdot T$. Neste caso, as estimativas das constantes de suavização e do período sazonal são determinados de modo adaptativo pelo uso do algoritmo genético (AG) (SIMON, 2013). Após alguns testes, foram usadas as seguintes características: tamanho da população de 100 indivíduos, taxa de recombinação igual a 0,08, método de seleção baseado na técnica elitista com taxa de 0,05, taxa de convergência de 10^{-6} ou tempo máximo de convergência de 5 s. A função de avaliação a ser minimizada pelo AG, definida pela média do erro absoluto médio (MAE) de previsão conforme Equação (3.9), é determinada a partir da janela móvel de dados históricos Mw_t ,

$$\text{MAE} = \sum_{i=h'_f}^n \sum_{k=1}^{h'_f} \frac{|Z_{t-i+k} - \hat{Z}_{t-i}(k)|}{h'_f(n - h'_f)}. \quad (3.9)$$

Deste modo, o procedimento iterativo para estimação das constantes de suavização α , β e γ e também do período sazonal s é descrito abaixo:

Passo 1) Para $iter = 0$ estima-se o período sazonal dos dados históricos da janela móvel Mw_t a partir da função de auto-correlação da série e em seguida são iniciadas as equações de recorrência de nível, tendência e sazonalidade da seguinte forma:

$$\bar{\mu}_t = \frac{1}{s} \sum_{k=1}^s Z_k, \quad t = 1, \dots, s; \quad (3.10)$$

$$\bar{T}_t = 0, \quad t = 1, \dots, s; \quad (3.11)$$

$$\bar{S}_t = Z_t - \bar{\mu}_t, \quad t = 1, \dots, s. \quad (3.12)$$

Passo 2) Depois, na iteração seguinte $iter = iter + 1$, aplica-se o algoritmo genético para estimar as constantes α , β e γ de modo a minimizar o erro absoluto médio da expressão definida pela Equação (3.8) com os dados históricos da janela móvel Mw_t . O algoritmo genético usado para estimação das constantes de suavização é finalizado quando a melhora do índice MAE , por nova solução, for inferior a um milionésimo em relação à melhor solução já encontrada, ou quando exceder o tempo de execução de 5 segundos.

A Tabela 7 apresenta os índices de validação da previsão individual das séries temporais de consumo de BFG e COG determinados a partir do método HW com parâmetros adaptativos. As últimas colunas mostram os índices de validação de previsão para a série temporal de consumo total de BFG não-controlado (TBFGc) e para a série temporal de consumo total de COG não-controlado (TCOGc), respectivamente, que são determinados pela soma das previsões individuais de cada consumo não-controlado dos gases BFG e COG.

As Figuras (14) (a) e (14) (b) mostram uma comparação entre a série temporal real e a série temporal prevista na próxima hora (60 passos à frente) para as séries de consumo

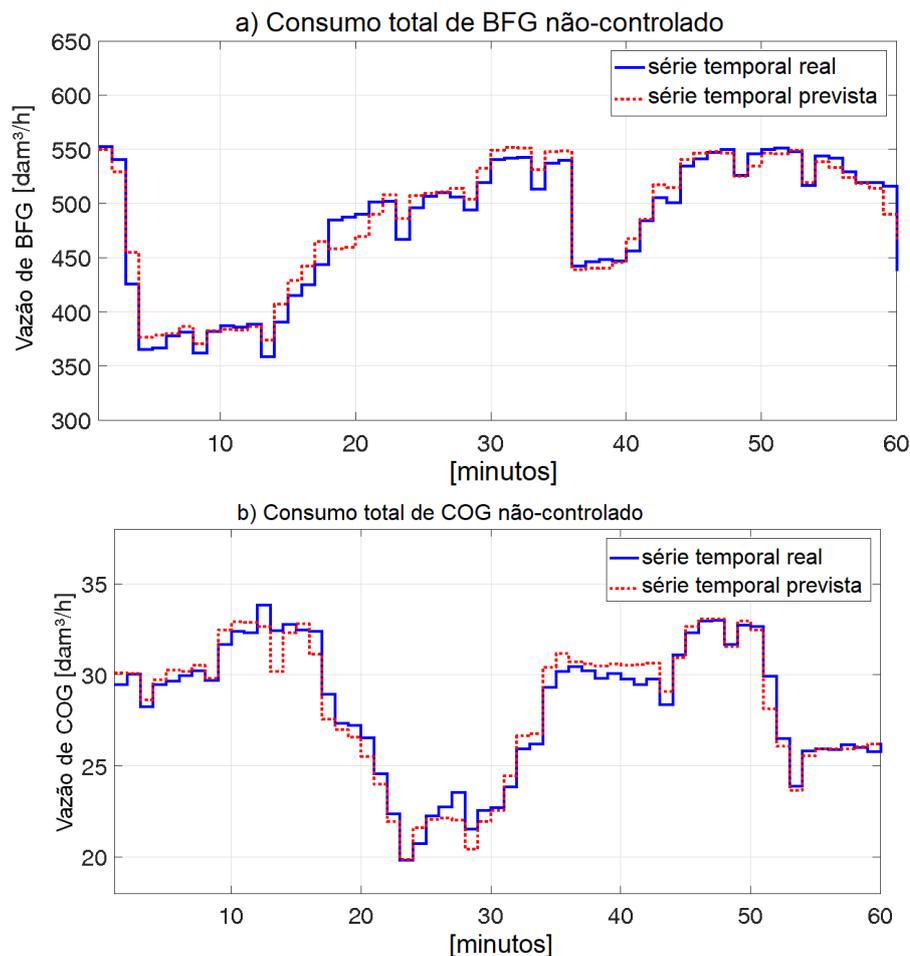
Tabela 7: Validação da previsão das séries temporais de consumo não-controlado dos gases BFG e COG (BF = Alto-Forno, CO = Coqueria).

Índices	BF#1	BF#2	BF#3	CO	TBFGc	TCOGc
\overline{MAPE} do BFG	6,3%	1,4%	2,6%	2,2%	1,2%	-
\overline{MAPE} do COG	1,5%	1,8%	5,5%	7,1%	-	1,9%

Fonte: elaboração própria.

total não-controlado de BFG e COG, respectivamente. Esses resultados são interessantes para ilustrar que o algoritmo de previsão é apto para trabalhar com diferentes bases de tempo, isto é, é possível escolher, como no exemplo apresentado na figura em questão, 60 previsões espaçadas de 1 em 1 minutos ou escolher 5 previsões espaçadas de 12 em 12 minutos (como é feito na etapa de otimização pelo modelo MILP). O trecho apresentado faz parte do conjunto de dados usado na validação das séries apresentadas.

Figura 14: Série temporal Real (linha azul) e Prevista (linha vermelha) pelo modelo Holt-Winters.



Fonte: elaboração própria.

3.3 Modelo de Previsão ARIMA

Modelos auto-regressivos e de médias móveis (ARMA - *autoregressive-moving-average*), caso particular do modelo auto-regressivo, integrado e de médias móveis (ARIMA - *autoregressive integrated moving average*), podem ser uma alternativa interessante para modelagem de séries temporais lineares, com um número não muito grande de parâmetros, quando essas séries não são descritas de modo aceitável por modelos de suavização exponencial.

As séries temporais da produção de BFG nos altos-fornos e COG na coqueria, do consumo de gás misto nas estações de mistura (HSM) e da demanda de eletricidade são modelados a partir do modelo ARIMA com parâmetros adaptativos. A equação a diferenças auto-regressiva e média móvel de uma série temporal Z_t é dada por (BOX et al., 2015):

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} + a_t, \quad (3.13)$$

em que a_t é um ruído aleatório no instante t , $\phi_1 \dots \phi_p$ são os parâmetros auto-regressivos, e $\theta_1 \dots \theta_q$ são os parâmetros de média móvel. A Equação (3.13) pode ser descrita pela seguinte função de transferência:

$$\phi(B)Z_t = \theta(B)a_t, \quad (3.14)$$

sendo B o operador de atraso, e $\phi(B)$ e $\theta(B)$ os respectivos operadores auto-regressivos e de média móvel de polinômios de ordens p e q . A Equação (3.14) representa apenas séries temporais estacionárias, porém se Z_t for uma série não-estacionária devido a uma componente de tendência, é então necessário realizar um número finito d de diferenças de Z_t até se obter uma série temporal estacionária W_t , isto é,

$$W_t = \Delta^d Z_t, \quad (3.15)$$

em que Δ^d realiza d -diferenças em Z_t .

A partir das Equações (3.14) e (3.15) uma série não-estacionária Z_t pode ser representada por um modelo ARIMA(p, d, q) definido por:

$$\phi(B)\Delta^d Z_t = \theta(B)a_t. \quad (3.16)$$

O número d de diferenças que uma série temporal não-estacionária requer para se tornar estacionária está relacionado à existência de raízes unitárias no polinômio $\phi(B)$, que pode ser detectada usando o teste de Dickey-Fuller aumentado (BOX et al., 2015). Uma maneira de identificar as ordens p e q é por meio da função de autocorrelação (fac) do resíduo do modelo ARIMA e da função de correlação cruzada (fcc) entre a série temporal e o modelo do resíduo. Devido às não-linearidades presentes nas séries temporais da produção do gás BFG e COG, é necessário identificar o modelo ARIMA(p, d, q) a partir desses testes e reestimar seus parâmetros a cada intervalo de tempo $h_c \cdot T$ a partir da

janela móvel de dados históricos Mw_t . Nesta tese, o tamanho da janela móvel é de 480 amostras, isto é, 8 horas de dados.

O modelo ARIMA(p, d, q) adaptativo é obtido por meio do seguinte procedimento:

Passo 1) Faça $iter = 0$ e $p = q = 0$ e determine d por meio do teste de Dickey-Fuller aumentado aplicado aos dados históricos da janela móvel Mw_t . Inicie o índice Akaike (BOX et al., 2015) com um número suficientemente grande;

Passo 2) Defina $iter = iter + 1$, e determine a função fac dos resíduos dos dados históricos W_t , e escolha o termo mais significativo de defasagem k que seja diferente de zero. Se esse termo significativo existir, então inclua um parâmetro de média móvel de ordem k no polinômio $\theta(B)$ e faça $q = q + 1$;

Passo 3) Determine a função fcc entre a série de dados históricos W_t e seus resíduos, e escolha o termo mais significativo de defasagem k que seja diferente de zero. Se esse termo significativo existir, então inclua um parâmetro auto-regressivo de ordem k no polinômio $\phi(B)$ e faça $p = p + 1$;

Passo 4) Estime os parâmetros do modelo ARIMA(p, d, q) dos dados históricos W_t , e calcule o índice Akaike. Se o índice Akaike atual for semelhante ao índice obtido na iteração anterior, pare; e, faça a previsão para próxima 1 hora ($\hat{Z}_t(k), k = 1 \dots h_f$, onde $h_f = 60$) dado Mw_t . Caso contrário, retorne ao Passo (2).

A Tabela 8 mostra os índices de validação da previsão individual das séries temporais de produção de BFG e COG obtidos pelo modelo ARIMA(p, d, q) com parâmetros adaptativos determinados a partir do método ARIMA. A validação da previsão da produção total de BFG (TBFGp) e da produção total de COG (TCOGp), que são determinadas pela adição de cada produção individual desses gases, pode ser encontrada nas últimas colunas desta tabela.

Tabela 8: Validação da previsão das séries temporais de produção dos gases BFG e COG (BF = Alto-Forno, CO = Coqueria).

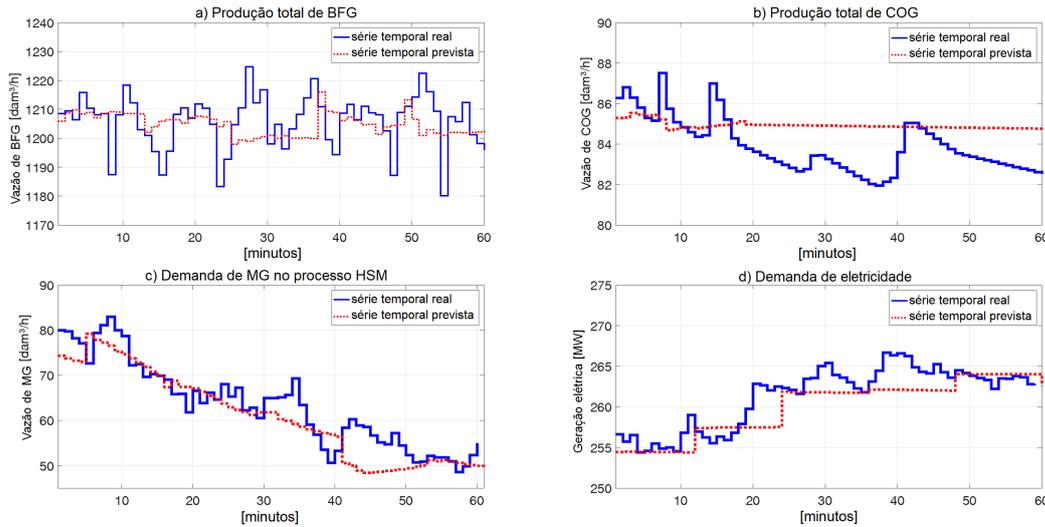
Índices	BF#1	BF#2	BF#3	CO	TBFGp	TCOGp
\overline{MAPE} of BFG	0,8%	1,5%	1,0%	-	0,6%	-
\overline{MAPE} of COG	-	-	-	2,0%	-	2,0%

Fonte: elaboração própria.

Outras séries temporais representadas pelo modelo ARIMA(p, d, q) são as demanda de gás misto (MG) no HSM e a demanda de eletricidade, cujos índices \overline{MAPE} são iguais a 10,1% e 1,5%, respectivamente. As Figuras 15 (a), (b), (c) e (d) mostram uma comparação entre a série temporal real e a série temporal prevista na próxima hora (60 passos à frente) para as séries de produção total de BFG e COG, de consumo de MG no HSM e da

demanda de eletricidade, respectivamente. Esses resultados ilustram também que o algoritmo de previsão é apto para trabalhar com diferentes bases de tempo, isto é, é possível escolher, como no exemplo apresentado na figura em questão, 60 previsões espaçadas de 1 em 1 minutos ao invés de escolher 5 previsões espaçadas de 12 em 12 minutos (como é feito na etapa de otimização pelo modelo MILP). O trecho apresentado faz parte do conjunto de dados usado na validação das séries apresentadas.

Figura 15: Série temporal Real (linha azul) e Prevista (linha vermelha) pelo modelo ARIMA.



Fonte: elaboração própria.

3.4 Modelo heurístico de previsão da produção de LDG

Nesta seção, é proposto um modelo linear original baseado em heurísticas, uma vez que as previsões da produção de LDG obtidas pelos métodos ARIMA ou HW não são satisfatórias, ou seja, seus índices de desempenho \overline{MAPE} são 60% e 70%, respectivamente.

É importante pontuar que o gás LDG é produzido em bateladas e que nem todo volume de LDG produzido pode ser usado efetivamente, porque uma porção é queimada devido ao baixo poder calorífico do LDG produzido em curtos intervalos de tempo. Outra parte é queimada caso o LDG produzido não possa ser enviado ao respectivo gasômetro quando o mesmo estiver completamente cheio. Assim, o volume de LDG efetivamente utilizado como combustível pelos operadores do centro de energia (denominado volume recuperado de LDG) é representado pela seguinte expressão:

$$Z_t^r = Z_t^p - Z_t^{bfs} - Z_t^{blc} \text{ para } Ti_r \leq t \leq Tf_r, \quad (3.17)$$

na qual Ti_r e Tf_r são os instantes inicial e final de recuperação de LDG, Z_t^r é o volume recuperado do LDG produzido, Z_t^p é o volume total produzido de LDG, Z_t^{bfs} é o volume

de LDG queimado nas torres de queima e Z_t^{blc} é o volume de LDG queimado devido ao baixo poder calorífico.

Sejam definidos os instantes inicial e final de sopro de oxigênio nos convertedores como $T_{i_{o_2}}$ e $T_{f_{o_2}}$, respectivamente. O intervalo de tempo entre o início do sopro de oxigênio e a recuperação de LDG é definido como $Li_t = T_{i_r} - T_{i_{o_2}}$. O intervalo de tempo entre o fim do sopro de oxigênio e a recuperação de LDG é definido como $Lf_t = |T_{f_r} - T_{f_{o_2}}|$, pois o fim da recuperação de LDG pode ocorrer antes ou após o término do sopro de oxigênio. Deste modo, como a estimativa da programação do sopro de oxigênio (i.e., $\hat{T}_{i_{o_2}}(k)$ e $\hat{T}_{f_{o_2}}(k)$, respectivamente) é conhecida *a priori* pelo plano de produção, com até uma hora de antecedência, determina-se a previsão dos instantes de recuperação de k -passos-à frente da série de LDG de acordo com:

$$\hat{T}_{i_r}(k) = \hat{T}_{i_{o_2}}(k) + \bar{L}i \text{ e } \hat{T}_{f_r}(k) = \hat{T}_{f_{o_2}}(k) + \bar{L}f, \quad (3.18)$$

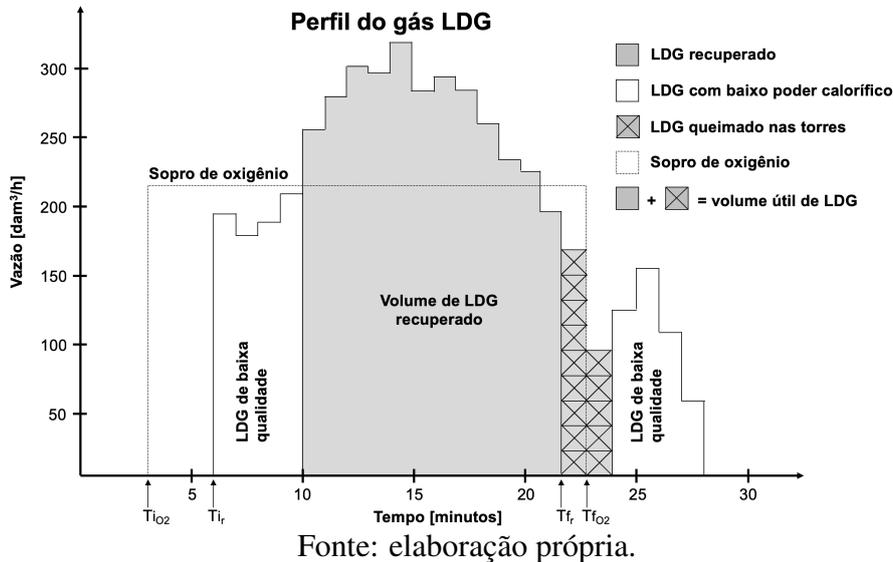
sendo $\bar{L}i$ e $\bar{L}f$ as médias de Li_t e Lf_t respectivamente, determinadas a partir de uma janela móvel de dados históricos Mw_t .

Define-se o volume útil do LDG produzido como:

$$Z_t^{uv} = Z_t^r + Z_t^{bfs} \quad (3.19)$$

A importância da previsão do volume útil de LDG ocorre porque essa informação é importante na otimização da recuperação do gás LDG, evitando assim o desperdício nas torres de queima. A Figura 16 ilustra um perfil do volume da produção de gás LDG.

Figura 16: Perfil da recuperação do gás LDG produzido.



Médias móveis das séries Z_t^r e Z_t^{bfs} , denominadas \bar{Z}_t^r e \bar{Z}_t^{bfs} , respectivamente, são obtidas com uma janela móvel de dados históricos.

Determina-se então a previsão k -passos-à frente do volume útil de LDG pela seguinte expressão:

$$\hat{Z}_t^{uv}(k) = \bar{Z}_t^r + \bar{Z}_t^{bfs} \text{ for } \hat{T}_{i_r}(k) \leq t + k \leq \hat{T}_{f_r}(k), \quad k = 1, \dots, h'_f \quad (3.20)$$

O algoritmo heurístico para previsão de LDG é descrito por:

Passo 1) Calcula a previsão k -passos-à frente dos instantes de recuperação $\hat{T}i_r(k)$ e $\hat{T}f_r(k)$;

Passo 2) Calcula a previsão k -passos-à frente do volume útil de LDG $\hat{Z}_t^{uv}(k)$;

Como $\hat{Z}_t^{uv}(k)$ pode assumir valor igual a zero, é preciso re-definir o erro absoluto como se segue:

$$\epsilon_t(k) = \begin{cases} |1 - \frac{\hat{Z}_t^{uv}(k)}{Z_{t+k}^{uv}}| & \text{se } Z_{t+k}^{uv} \neq 0 \\ 0 & \text{se } Z_{t+k}^{uv} = \hat{Z}_t^{uv}(k) = 0 \\ 1 & \text{se } Z_{t+k}^{uv} = 0 \text{ e } \hat{Z}_t^{uv}(k) \neq 0 \end{cases} \quad (3.21)$$

Note que $\epsilon_t(k) = 1$ se os seguintes eventos ocorrerem: E1 = $\hat{Z}_t^{uv}(k) \neq 0$ e $Z_{t+k}^{uv} = 0$ ou E2 = $\hat{Z}_t^{uv}(k) = 0$ e $Z_{t+k}^{uv} \neq 0$. Os eventos E1 e E2 são verdadeiros se a previsão do instante de recuperação não for corretamente determinada pelo algoritmo de previsão. Essa situação pode ocorrer, pois essas estimativas são afetadas por incertezas da programação do sopro de oxigênio, que é feita com uma previsão de uma hora à frente. Se o evento E3 = (E1 U E2)^c (complemento do conjunto E1 U E2) é verdadeiro, então $0 \leq \epsilon_t(k) < 1$.

A partir da análise de dados históricos, são obtidas as probabilidades condicionais desses eventos em relação a cada produtor individual (CV#1, CV#2 and CV#3) (veja Tabela 9). A última coluna desta tabela mostra a probabilidade total de eventos E1UE2 e E3 associados ao volume útil total de LDG (TLDG^{uv}), isto é, a soma dos volumes úteis individuais de LDG. Este valor é determinado a partir do teorema da probabilidade total considerando uma ocorrência de produção igualmente provável nos convertedores CV#1, CV#2 e CV#3.

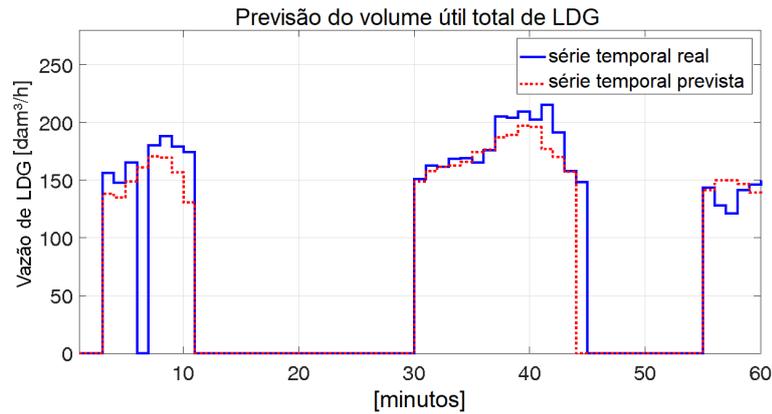
Tabela 9: Probabilidade dos eventos E1 U E2 e E3.

Eventos	CV#1	CV#2	CV#3	TLDG ^{uv}
E1 U E2	0,10	0,11	0,12	0,11
E3	0,90	0,89	0,88	0,89

Fonte: elaboração própria.

Os índices \overline{MAPE} do volume útil LDG dos convertedores CV#1, CV#2 e CV#3 são iguais a 17,7%, 19,1% e 21,4%, respectivamente, e 19,4% para o volume útil total do LDG. No entanto, se os instantes de recuperação de LDG não forem corretamente estimados, o valor condicional do índice \overline{MAPE} relacionado ao volume útil total da produção LDG será igual a 11%. Caso contrário, o valor condicional do índice \overline{MAPE} é igual a 8,4%. A Figura 17 mostra a comparação entre a previsão do volume útil total de LDG na próxima hora (60 passos à frente) e sua série temporal real.

Figura 17: Série temporal Real (linha azul) e Prevista (linha vermelha) do total de LDG útil produzido.



Fonte: elaboração própria.

3.5 Modelo de Média Móvel

As séries temporais apresentadas na Tabela 10 são melhor modeladas usando média móvel (MA - *moving-average*) do que HW e ARIMA. Os modelos de média móvel foram determinados variando suas respectivas ordens de 5 a 40 (1h a 8h); o melhor resultado para todos os modelos de séries temporais foi o de ordem 5. Isto é, a previsão k -passos-à frente de Z_t é dada por:

$$\hat{Z}_t(k) = \frac{1}{\Delta T} \sum_{i=(k-1)\Delta T+1}^{k\Delta T} Z_i. \quad (3.22)$$

Mesmo que os erros nas séries temporais usadas para a previsão do vapor de processo e para a previsão do consumo de BFG no PCI sejam grandes, será mostrado no Capítulo 4 que esses erros não diminuem a eficiência do algoritmo de planejamento da distribuição de gases siderúrgicos, porque essas séries temporais representam apenas 1,75% da produção total de vapor nas termoeletricas e 1,9% da produção total de BFG.

Tabela 10: \overline{MAPE} da previsão da extração de vapor de processo, do consumo de LDG na calcinação e de BFG no PCI.

Series Temporais	ARIMA	HW	MA
extração de Vapor de Processo	222%	235%	40%
consumo de LDG na Calcinação	33%	27%	7,5%
consumo de BFG no PCI	9%	12%	5%

Fonte: elaboração própria.

4 Simulações e resultados

Neste capítulo, primeiramente são apresentados os resultados das simulações computacionais para o algoritmo de controle por horizonte rolante aplicado ao modelo MILP multi-período do problema de otimização do sistema de distribuição de combustíveis siderúrgicos. Depois, são apresentados os resultados das simulações dos procedimentos de sintonia dos parâmetros deste modelo pelo método de otimização por enxame de partículas.

4.1 Simulações Computacionais

Nesta seção, o desempenho do algoritmo de controle por horizonte rolante proposto no Capítulo 2 será analisado a partir de resultados obtidos por simulação computacional. As simulações foram realizadas tomando como base as equações do modelo MILP descrito no Capítulo 2 e fazendo uso dos modelos de previsão estudados no Capítulo 3. Os parâmetros de tais equações foram obtidos de uma planta industrial real e são apresentados na sequência.

O sistema de distribuição de combustível considerado contém quatro centrais termelétricas, com um total de quatro caldeiras, quatro turbinas e duas estações de mistura (ver Figura 1). As características operacionais de queimadores, caldeiras e turbinas são apresentadas nas Tabelas 11 e 12.

A Tabela 11 apresenta o tipo e a quantidade de queimadores em cada caldeira, além da vazão máxima de cada queimador dos combustíveis citados e da relação TDR. Nesta planta industrial, os queimadores de gás BFG podem ser usados para a queima de gás misto, e o uso do gás LDG ocorre apenas na fornalha da caldeira #4.

A Tabela 12 apresenta informações sobre as caldeiras e turbinas, como: os rendimentos da caldeira, da turbina e da extração de vapor na turbina; a entalpia da água de alimentação das caldeiras (H^{water}), os valores típicos de entalpia do vapor na entrada da turbina (H^{stm}), na extração secundária da turbina (H^{exh}) e na exaustão (saída) da turbina; e a máxima vazão de vapor que cada caldeira pode produzir e que cada turbina pode admitir.

Neste estudo, o poder calorífico dos combustíveis foi considerado constante durante toda a simulação. Os valores usados na simulação são apresentados na Tabela 13. Por definição, o poder calorífico de um combustível é a quantidade de energia que é liberada durante a combustão completa da unidade de massa [1 kg] ou unidade de volume [1 Nm^3]

Tabela 11: Informações gerais sobre os queimadores.

Caldeira	Combustível	Quantidade	Capacidade máxima por unidade	TDR*
#1	BFG	4 × 2 unidades	29160 m ³ /h	1,333:1
#1	COG	8 × 1 unidades	4212 m ³ /h	1,333:1
#1	TAR	8 × 1 unidades	2203 kg/h	1,333:1
#2	BFG	4 × 2 unidades	29160 m ³ /h	1,333:1
#2	COG	8 × 1 unidades	4212 m ³ /h	1,333:1
#2	TAR	8 × 1 unidades	2203 kg/h	1,333:1
#3	BFG	8 × 1 unidades	30618 m ³ /h	1,429:1
#3	COG	8 × 1 unidades	2722 m ³ /h	1,176:1
#3	TAR	8 × 1 unidades	2074 kg/h	1,429:1
#4	BFG	8 × 1 unidades	30618 m ³ /h	1,429:1
#4	COG	8 × 1 unidades	2722 m ³ /h	1,176:1
#4	LDG	8 × 2 unidades	5589 m ³ /h	1,163:1
#4	TAR	8 × 1 unidades	2074 kg/h	1,429:1

Fonte: Oliveira Júnior (2016)

*Turn-down ratio (TDR) é a relação entre as capacidades máxima e mínima de liberação de calor nos queimadores sem risco de apagamento da chama do queimador.

Tabela 12: Características Operacionais das caldeiras e turbinas.

Parâmetros	Caldeiras				Turbinas			
	#1	#2	#3	#4	#1	#2	#3	#4
η_j^B (%)	80	80	85	85	-	-	-	-
η_j^T (%)	-	-	-	-	70	64.6	73.1	65.6
η_j^{ext} (%)	-	-	-	-	78.4	93.1	27.8	52.1
H_j^{water} (kJ/kg)	1160	1160	1160	1160	-	-	-	-
H_j^{stm} (kJ/kg)	-	-	-	-	3470	3470	3470	3470
H_j^{exh} (kJ/kg)	-	-	-	-	2061	2099	2112	2114
H_j^{ext} (kJ/kg)	-	-	-	-	3246	3222	3319	3325
$f_{max,j}^{stm}$ (t/h)	270	270	270	270	-	-	-	-
$f_{max,j}^{tb}$ (t/h)	-	-	-	-	260	260	270	270

Fonte: dados da usina ArcelorMittal citada.

do combustível, podendo ser medida em [kJ/kg] ou [kJ/Nm³]. No caso do gás misto, foram considerados os seguintes limites inferior e superior para o poder calorífico dos gases produzidos nas estações de mistura #1 e #2: 14,0 [MJ/m³] e 14,3 [MJ/m³], respectivamente.

Em condições normais de operação, as estações de mistura produzem no mínimo 11 dam³/h de MG cada. A Tabela 14 apresenta os limites máximos para operação normal das estações de mistura (MS-Mixing Station), como: as vazões máximas dos gases BFG, COG e NG para a primeira das estações e as vazões máximas dos gases COG e LDG para

Tabela 13: Poder calorífico.

Poder calorífico		
BFG	3,4	$[MJ/m^3]$
COG	17,6	$[MJ/m^3]$
LDG	8,0	$[MJ/m^3]$
NG	47,1	$[MJ/m^3]$
MG	14,2	$[MJ/m^3]$
TAR	37,7	$[MJ/kg]$

Fonte: dados da usina ArcelorMittal citada.

a segunda delas; além disso, mostra qual a vazão máxima de MG produzida em cada uma das estações de mistura, e as vazões máximas de MG para o processo HSM, de MG para produção de eletricidade nas termoelétricas (PP-*Power Plant*) e de MG para as torres de proteção das estações de mistura (FS-*Flare Stack*).

Tabela 14: Limites máximos para operação das estações de mistura.

Gases (dm^3/h)	MS #1	MS #2	HSM	PP	FS
BFG	60	-	-	-	-
COG	40	40	-	-	-
LDG	-	80	-	-	-
NG	6	-	-	-	-
MG	120	120	104	40	40

Fonte: dados da usina ArcelorMittal citada.

As penalidades usadas no cálculo dos custos operacionais (ver J_{op} da Equação (2.2)) e dos custos econômicos (ver J_{ec} da Equação (2.3)) que compõem a Função Objetivo (ver Equação (2.1)) apresentada no Capítulo 2 são encontradas, respectivamente, nas Tabelas 15 e 16.

No caso, os valores dos pesos da Tabela 15 são os mesmos apresentados por (OLIVEIRA; PENA; SALLES, 2016) como resultado de um procedimento heurístico.

Por outro lado, os valores apresentados na Tabela 16 são os custos dos combustíveis usados nas termoelétricas, nas estações de mistura e desperdiçado nas torres de proteção; também o custo do vapor de processo extraído nas termoelétricas e distribuído para a planta industrial e o preço de venda de eletricidade.

Nas simulações realizadas, o tempo total de planejamento é $T_s = 1440$ minutos. (24 horas) e o tempo total de previsão é $T_f = 60$ minutos. Logo, $h_s = 120$ e $h_f = 5$ amostras, pois a otimização do programa MILP é realizada a cada $T = 12$ minutos. Todas as simulações foram executadas num computador com processador *i7 7500U* de 2,9 GHz. As previsões de uma hora à frente da produção total e do consumo total de gases siderúrgicos,

Tabela 15: Custos operacionais aplicados à Expressão (2.2).

Pesos	BFG	COG	LDG	TAR
W_H	$1,2729 \cdot 10^{-2}$	$7,4253 \cdot 10^{-2}$	$3,7127 \cdot 10^{-2}$	-
W_L	$8,9104 \cdot 10^{-3}$	$2,4751 \cdot 10^{-2}$	$1,2376 \cdot 10^{-2}$	-
W_{sw}	400	300	500	1000
W_{2s}	800	600	1000	2000
W_{3s}	1200	900	1500	3000

Fonte: Oliveira, Pena e Salles (2016).

Tabela 16: Custos aplicados à Expressão (2.3).

Custos	Insumos	Unidades de medida
C^{BFG}	0,0127	$US\$/m^3$
C^{COG}	0,0659	$US\$/m^3$
C^{LDG}	0,0300	$US\$/m^3$
C^{TAR}	2,1424	$US\$/kg$
C^{NG}	3,7439	$US\$/m^3$
C^{MG}	0,0270	$US\$/m^3$
C^{PS}	0,0302	$US\$/kg$
C^{Elec}	0,2717	$US\$/kWh$

Fonte: Oliveira, Pena e Salles (2016).

assim como as previsões das demandas de vapor de processo, eletricidade e gás misto são realizadas em série, ou seja, uma de cada vez. Deste modo, o tempo médio necessário para realizar todas as previsões das séries temporais cujos modelos foram apresentados no Capítulo 3 é igual a 31,621 s (veja Tabela 5). Este tempo é menor que o intervalo de amostragem do sistema de dados de aquisição ($\Delta T = 1$ minuto), e muito menor que T. O problema de otimização do MILP foi resolvido a partir do algoritmo apresentado no Capítulo 2. O tempo médio de processamento é igual a 0,9 segundos. Assim, a soma dos tempos de previsão e otimização é menor que o intervalo do sistema de aquisição de dados.

4.1.1 Resultados do algoritmo de horizonte de rolagem

Em seguida, será discutido o desempenho do algoritmo de controle com horizonte rolante aplicado à resolução do problema de planejamento de curto prazo proposto nesta tese. As previsões com incertezas das séries temporais, obtidas pela aplicações dos modelos já discutidos, são usadas considerando horizontes de controle iguais a 1 e 5, os quais serão aqui denotados como RHE1 e RHE5, respectivamente. A fim de analisar os efeitos

do erro de previsão na solução do problema, essas estratégias serão comparadas com as estratégias de controle com horizonte rolante considerando os horizontes de previsão perfeita e de controle iguais a 1 e 5, denotados por RHPF1 e RHPF5. Ou seja, sem incerteza nas séries temporais.

Essas estratégias determinísticas têm menores custos computacionais do que RHE1 e RHE5, respectivamente, porque as informações futuras no RHPF1 e RHPF5 são conhecidas *à priori*, isto é, os dados de previsão são idênticos aos dados reais e, portanto, não há esforço computacional para calcular suas previsões.

O algoritmo de horizonte rolante nas estratégias RHE1 e RHPF1 precisa de 120 iterações para resolver o problema de planejamento, ou seja, o problema de otimização de MILP é resolvido em cada intervalo de tempo igual a $T = 12$ minutos. Por outro lado, nas estratégias RHE5 e RHPF5, o planejamento é realizado em 24 iterações, ou seja, o problema de otimização do MILP é resolvido a cada intervalo de tempo igual a $5T$, isto é, o deslizamento da janela ocorre a cada 60 minutos.

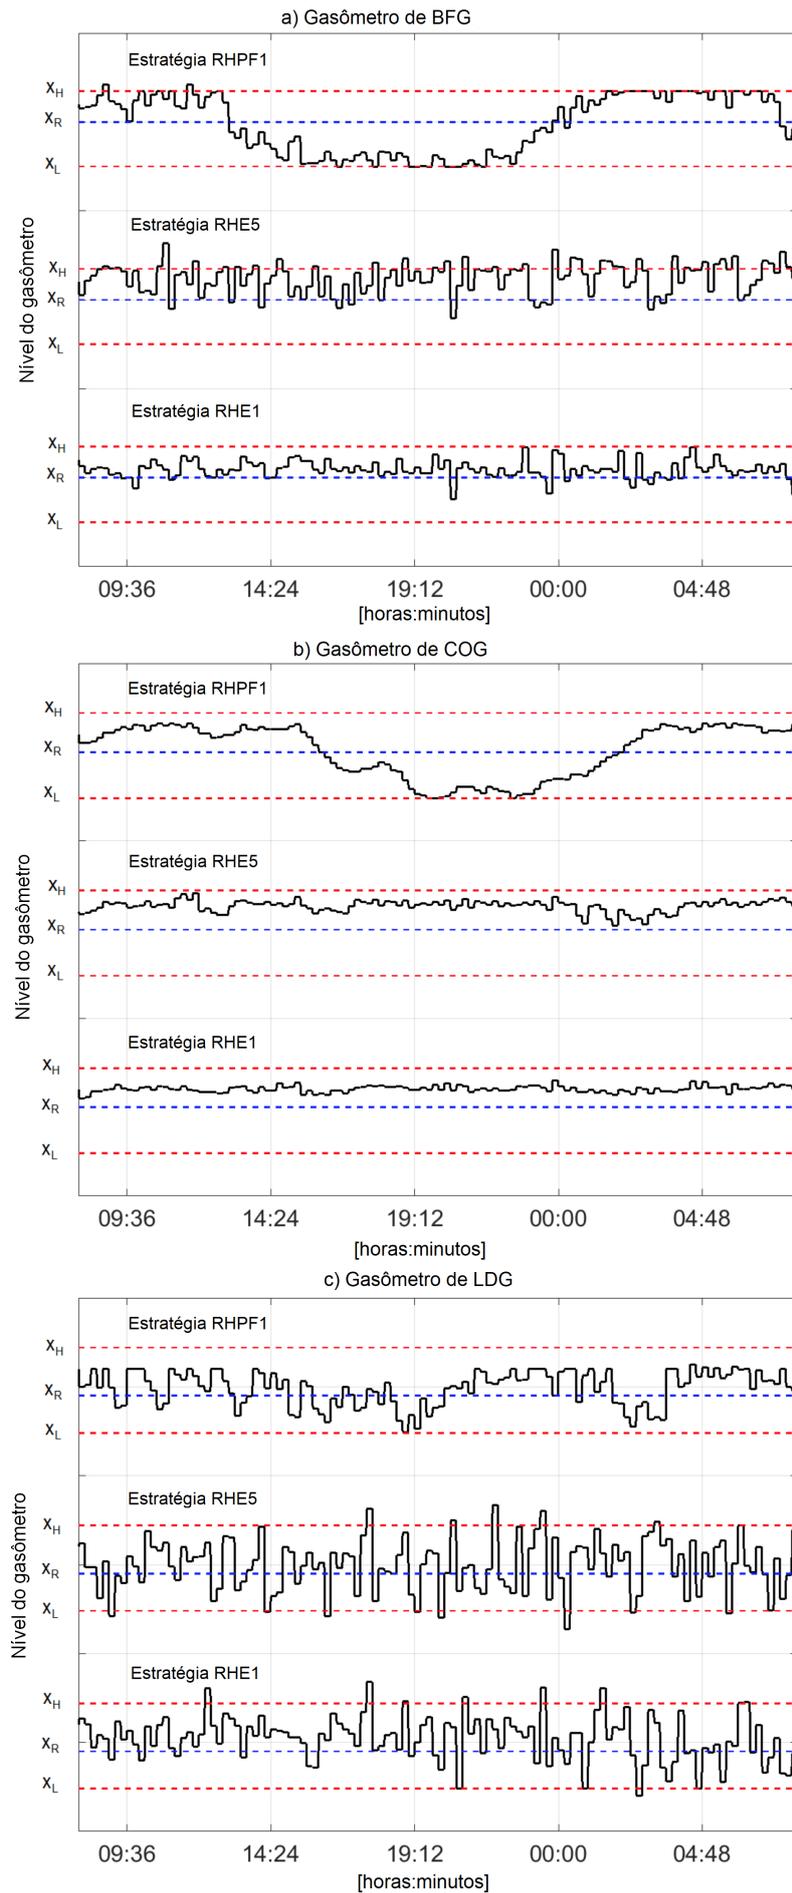
Oliveira, Pena e Salles (2016) utilizaram uma estratégia equivalente a RHPF5 na resolução do problema determinístico de planejamento da distribuição de gases siderúrgicos. Essa estratégia requer menos capacidade computacional do que o RHPF1. No entanto, produz uma solução pior que a solução obtida pela estratégia RHPF1, sob a perspectiva de eficiência energética, como será mostrado nesta seção.

Os limites operacionais dos gasômetros são apresentados na Tabela 17. Observe nas Figuras 18 (a), (b) e (c) que oscilações ocorrem nos níveis dos gasômetros por causa do comportamento dinâmico do sistema como um todo, e principalmente por conta das variações aleatórias na produção e consumo dos gases siderúrgicos. Observe que essas oscilações podem atingir valores acima ou abaixo dos níveis máximo e mínimo de segurança x_H e x_L , respectivamente.

Quando o nível aumenta e alcança o limite superior máximo do gasômetro, a torre de proteção do equipamento em questão começa a queimar gás de modo a impedir que o nível alcance a capacidade máxima do gasômetro. Por outro lado, quando o nível abaixa e alcança o limite inferior mínimo, é dito que houve uma falta, isto é, uma escassez de gás também chamada de *shortage*, indicando quando o nível do gasômetro fica abaixo do limite inferior mínimo, porém acima do nível mínimo crítico.

A Tabela 18 relata a queima e a falta de gás nos gasômetros dos gases *BFG*, *COG* e *LDG*, conforme simulações apresentadas nas Figuras 18 (a), (b) e (c), além da queima de gás misto nas torres de proteção das estações de mistura. Os resultados das estratégias RHPF1 e RHPF5 são melhores que os resultados alcançados pelas estratégias RHE1 e RHE5. Isso é esperado, pois as estratégias RHPF1 e RHPF5 trabalham com previsões sem incertezas, isto é, as séries temporais futuras são conhecidas com antecipação e sem erros, enquanto que as estratégias RHE1 e RHE5 usam modelos de previsão com incertezas.

Figura 18: Nível dos gasômetros segundo estratégias RHE1, RHE5 e RHPF1.



Fonte: elaboração própria.

Tabela 17: Limites Operacionais dos Gasômetros (dam^3).

Limites Operacionais	BFG	COG	LDG
Capacidade máxima (x_{HH}^G)	150	40	80
Limite superior máximo (x_H^G)	135	36	72
Nível visado de operação (x_R^G)	100	30	60
Limite inferior mínimo (x_L^G)	50	12	24
Nível mínimo crítico (x_{LL}^G)	35	8	12

Fonte: Oliveira, Pena e Salles (2016).

Os resultados também mostram que a estratégia RHE1 é melhor que a estratégia RHE5, isso ocorre porque a estratégia RHE5 demora 5 vezes mais para realizar a atualização das informações do sistema em relação à estratégia RHE1. Essa demora corresponde a atrasos na realimentação (*feedback*) da malha de controle, pois, neste caso, o algoritmo espera um período maior para fazer a rolagem da janela deslizante, isto é, a atualização dos dados medidos é feita com menor frequência e portanto, as correções das incertezas de previsão são realizadas num ritmo reduzido, como consequência, aumentando os efeitos que os erros de previsão provocam na solução do problema. Assim, os níveis dos gasômetros sofrem maiores variações e, no estudo realizado, produzem maiores queimas e também falta de gás.

Tabela 18: Queima de gás nas torres de proteção e escassez nos gasômetros.

Estratégia	BFG (dam^3/h)		COG (dam^3/h)		LDG (dam^3/h)		MG (dam^3/h)
	S_L	S_H	S_L	S_H	S_L	S_H	S_M
RHPF1	0,0	0,06	0,0	0,0	0,0	0,02	0,0
RHPF5	0,0	0,08	0,0	0,0	0,0	0,02	0,0
RHE1	0,0	0,0	0,0	0,0	0,03	0,37	2,25
RHE1*	0,0	0,03	0,0	0,0	0,0	0,34	2,25
RHE5	0,0	2,41	0,0	0,01	0,2	0,29	3,95

Fonte: elaboração própria.

Na Tabela 18 é observado que as estratégias RHE1 e RHE5, em razão de queimarem uma maior quantidade de gás nas torres de proteção dos gasômetros e estações de mistura, apresentam uma maior escassez de gás em relação às estratégias RHPF1 e RHPF5. Isto ocorre porque a queima indevida de gás no gasômetro num momento pode provocar uma condição de escassez num momento posterior. Observa-se, portanto, que a soma de todos os S_H com S_M são maiores nas estratégias RHE5 e RHE1 que nas estratégias RHPF5 e RHPF1, respectivamente; e, também que a soma dos S_L nas estratégias RHE5 e RHE1 são maiores que nas estratégias RHPF5 e RHPF1.

A maior diferença entre as estratégias que usam previsão perfeita e as que usam os

modelos de previsão propostos nesta tese ocorre na queima de gás misto, devido, principalmente, aos erros de previsão das séries de produção total de LDG (19,4%), de consumo de LDG no processo de calcinação (7,5%) e de demanda de gás misto para o processo HSM (10,1%). Isso ocorre por causa da interação entre essas séries temporais nas equações de restrições relacionadas às estações de mistura.

A partir da Tabela 18 observa-se também que, embora menor que na estratégia RHE5, há uma pequena quantidade de falta de gás LDG na estratégia RHE1. Elimina-se essa situação com a seguinte modificação: inserindo-se no modelo MILP o valor igual a 28 dam^3 para o limite inferior mínimo do gasômetro de LDG ao invés de 24 dam^3 (veja RHE1* na Tabela 18). Todavia, a simulação RHE1* não evitou a queima de gás, que inclusive foi maior para o gás BFG, porém ainda assim menor que a queima realizada segundo estratégia RHE5.

A distribuição dos combustíveis gasosos para as termoeletricas e estações de mistura, segundo as estratégias RHPF1, RHPF5, RHE1 e RHE5, pode ser encontrada na Tabela 19. Nas simulações realizadas, segundo cada estratégia em estudo, não houve consumo de alcatrão em nenhuma delas.

Tabela 19: Vazões médias do consumo de combustíveis gasosos nas termoeletricas (PP) e nas estações de mistura (MS).

Estratégia		BFG	COG	LDG	MG	NG	*Energia	Eletricidade
		(dam^3/h)	(GJ/h)	(MW)				
RHPF1	PP	542,72	27,45	0,00	0,00	-	2328,4	259,86
	MS	27,75	19,83	10,68	-	0,00	528,8	-
RHPF5	PP	529,7	27,4	0,00	0,00	-	2283,2	256,69
	MS	28,36	19,85	10,04	-	0,00	526,1	-
RHE1	PP	544,24	25,39	0,00	0,00	-	2297,3	256,58
	MS	28,51	20,41	11,59	-	0,00	548,87	-
RHE1*	PP	544,27	25,39	0,00	0,00	-	2298,5	256,58
	MS	28,11	20,33	12,07	-	0,00	549,9	-
RHE5	PP	509,99	27,85	0,00	0,00	-	2224,1	255,39
	MS	31,01	21,37	9,83	-	0,00	560,2	-

*A energia foi calculada considerando os seguintes valores caloríficos para os combustíveis: $C_v^{BFG} = 3,4 \text{ MJ/m}^3$, $C_v^{COG} = 17,6 \text{ MJ/m}^3$, $C_v^{LDG} = 8,0 \text{ MJ/m}^3$, $C_v^{NG} = 47,1 \text{ MJ/m}^3$ e $C_v^{MG} = 14,2 \text{ MJ/m}^3$.

Fonte: elaboração própria.

Observa-se na Tabela 19 que as estratégias com menor erro de previsão e com menor horizonte de controle são as estratégias que enviam uma maior quantidade de energia para as termoeletricas e menores quantidades de energia para as estações de mistura. Conseqüentemente, essas estratégias produzem, em média, mais eletricidade. Deste modo, quando compara-se RHPF1 com RHPF5 e RHE1 com RHE5 nota-se que a produção de energia elétrica diminui quando o horizonte de controle aumenta e quando compara-se RHPF1 com RHE1 e RHPF5 com RHE5 nota-se que a produção de energia elétrica dimi-

nui quando o erro de previsão aumenta. Observa-se também que as estratégias RHPF5 e RHE1 fornecem quase a mesma geração de eletricidade. Em (OLIVEIRA; PENA; SALLES, 2016) mostrou-se que a estratégia RHPF5 produz 9,83% a mais de eletricidade em relação à estratégia de gerenciamento realizada pelos operadores. Portanto, este ganho energético também ocorreria ao se comparar a estratégia RHE1 com a praticada pelos operadores da central termoeétrica.

No entanto, quando o horizonte de controle aumenta de 1 para 5, a redução na geração elétrica varia de 1,2% (RHPF5) a 1,7% (RHE5) em relação à estratégia RHPF1. Isso ocorre por dois motivos: primeiro porque o gás BFG (gás mais produzido na usina) e o gás COG (dentro os gases siderúrgicos, o de maior poder calorífico) são os principais gases usados nas fornalhas das caldeiras das termoeletricas (ver Tabela 19); segundo porque os modelos de previsão das séries de produção e consumo não-controlado de BFG e COG têm boa exatidão, isto é, eles têm índices \overline{MAPE} menores que 2%. Deste modo, a disponibilidade de BFG e COG é suficientemente conhecida com antecipação necessária, de modo que as alterações na produção de eletricidade são pequenas, mesmo quando o horizonte de controle aumenta de 1 para 5.

O vapor de processo extraído das caldeiras e turbinas equivale a 1,75% do total de vapor produzido nas caldeiras. Na simulação do problema de planejamento com erros de previsão somente na série de vapor de processo e com horizonte de controle igual a 1 (RHPF1*), houve uma redução de 2,30 MW em relação ao RHPF1 original. Com horizonte de controle igual a 5, a redução foi ligeiramente maior (neste caso, houve uma redução de 2,34 MW pela estratégia RHPF5* em relação à RHPF5 original). Portanto, o erro de previsão da série de vapor de processo provoca uma redução na geração de eletricidade de aproximadamente 0,9%, seja pela estratégia com horizonte 1 ou 5. Assim, embora o erro de previsão do vapor de processo seja grande ($\overline{MAPE} = 40\%$), seu efeito na geração de energia elétrica é pequeno.

O efeito que a série de consumo de BFG no PCI produz na geração elétrica é melhor explicado quando a estratégia RHPF1 é comparada com a estratégia RHPF5** (simulação do problema de planejamento com erros de previsão somente na série de consumo de BFG no PCI e com horizonte de controle igual a 5). No primeiro caso (RHPF1), o algoritmo proposto reserva 20,2 dam^3/h , em média, de BFG para consumo no PCI e, no segundo caso (RHPF5**), o algoritmo reserva 21,2 dam^3/h , em média. Essa diferença produz uma redução na disponibilidade de BFG para as termoeletricas que provoca uma redução de 3,49 MW, portanto uma redução de aproximadamente 0,12% (319,43 kW) em comparação com a estratégia RHPF5 original. Conseqüentemente, observa-se que o erro de previsão dessa série, que em média é igual a 5%, provoca uma redução insignificante mesmo no pior caso de simulação, quando o horizonte de controle aumenta de 1 para 5.

Os erros de previsão da série de LDG para calcinação, que é de 7,5%, provocaram apenas uma maior queima de LDG nas estações de mistura, porém não afetaram diretamente a geração de eletricidade, pois não houve consumo de LDG nas termoeletri-

cas, conforme mostra Tabela 19. Isso pode ser constatado quando compara-se a estratégia RHPF1** (simulação do problema de planejamento com erros de previsão somente na série de consumo de LDG na Calcinação e com horizonte de controle igual a 1) com a estratégia RHPF1 original ou quando compara-se a estratégias RHPF5*** (simulação do problema de planejamento com erros de previsão somente na série de consumo de LDG na Calcinação e com horizonte de controle igual a 5) com a estratégia RHPF5 original (ver Tabela 20).

A Tabela 20 resume o que foi comentado nos últimos parágrafos, ou seja, que os erros de previsão obtidas pelos modelos de média móvel aplicados nas séries temporais de extração de vapor de processo, de consumo de BFG no PCI e de consumo de LDG na Calcinação, apesar de grandes, não afetam o desempenho do algoritmo de planejamento.

Tabela 20: Impacto dos modelos de previsão de média móvel na geração elétrica.

Estratégia	RHPF1	RHPF1*	RHPF1**	RHPF5	RHPF5*	RHPF5**	RHPF5***
Eletricidade	259,86	257,56	259,86	256,69	254,35	256,37	256,69

Fonte: elaboração própria.

4.2 Resultados da sintonia dos parâmetros do modelo MILP

Como visto no Capítulo 2, uma das dificuldades de implementação do algoritmo de controle por horizonte rolante é a escolha dos parâmetros do controlador. Aliás, a escolha desses parâmetros é uma exigência para o adequado funcionamento do controlador, pois esses parâmetros afetam diretamente a qualidade dos índices de desempenho do sistema.

Tabela 21: Simulações PSO realizadas.

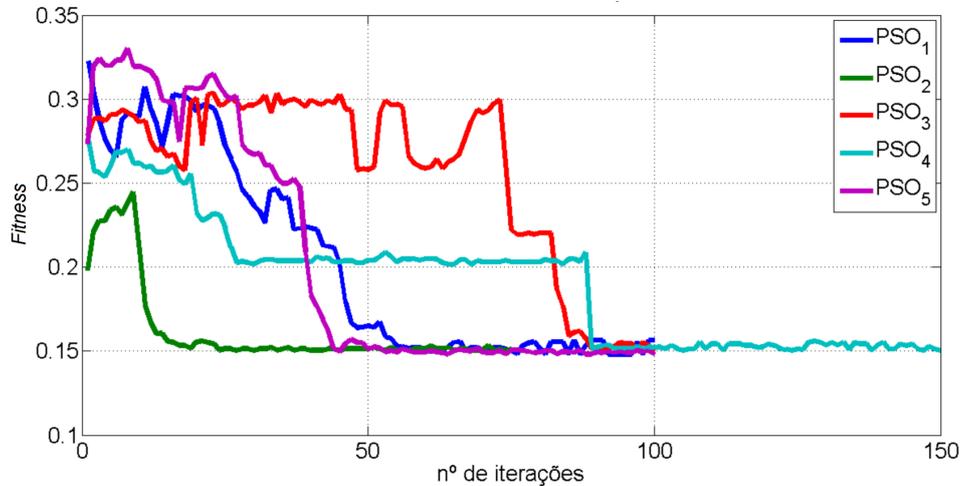
	Nº de partículas	Nº de iterações	Tempo simulação	<i>Fitness</i>
<i>PSO</i> ₁	40	100	5,00 dias	0,1481
<i>PSO</i> ₂	50	75	4,69 dias	0,1504
<i>PSO</i> ₃	50	100	6,25 dias	0,1503
<i>PSO</i> ₄	50	150	9,38 dias	0,1503
<i>PSO</i> ₅	60	100	7,50 dias	0,1481

Fonte: elaboração própria

Nesta tese, o uso do PSO é proposto na Seção 2.3. Na seqüência serão apresentados resultados deste estudo. Neste caso, o fator de inércia, a componente cognitiva e o componente social foram ajustados com o valor empírico igual a 0,5. A função de avaliação é expressa pela Equação (2.45) e tem como objetivo minimizar a soma dos índices normalizados ABS_N , AEP_N , $DGHL_N$, $ELFS_N$ e $UTAR_N$. Foi utilizado o mesmo algoritmo de controle por horizonte rolante apresentado, mas com horizonte de planejamento igual a 24 horas. Foram realizadas simulações conforme Tabela 21.

A Figura 19 apresenta a evolução, ao longo das iterações, da função objetivo (FO) da melhor partícula de cada uma das simulações com PSO. Observa-se que:

Figura 19: Comparação da função de avaliação da melhor partícula de cada modelo PSO simulado.



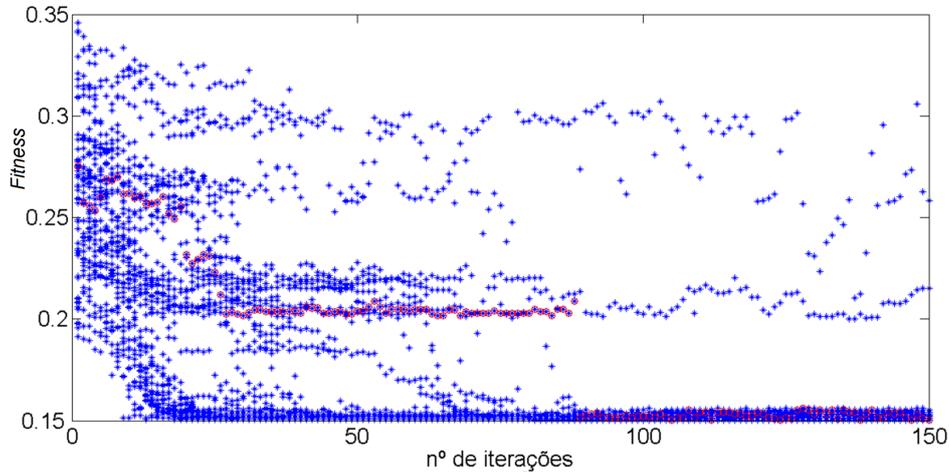
Fonte: elaboração própria.

- O resultado final é praticamente o mesmo em todos os casos, isto é, o custo encontrado é em torno de 0,15.
- Comparando-se as trajetórias da melhor partícula dos modelos PSO_1 , PSO_3 e PSO_5 , não é possível afirmar que o aumento do número de partículas tenha melhorado a resposta. Assim, ao longo do trabalho serão usadas 50 partículas, considerando-se que este número garante uma cobertura adequada do espaço de busca.
- Comparando-se as trajetórias da melhor partícula dos modelos PSO_2 , PSO_3 e PSO_4 , pode-se concluir que: a) o melhor desempenho em todos os casos foi encontrado antes da centésima iteração. b) foi antecipada a convergência do modelo PSO_2 . Neste caso, fica o alerta de que, eventualmente, o sistema pode não ter tempo suficiente de fazer uma investigação ampla do espaço de busca e, portanto, uma boa solução prematura pode prevalecer, ao invés de se encontrar uma solução melhor. c) a solução PSO_4 , apesar de ser resultado de um maior número de iterações, não foi melhor que as demais. Neste caso, fica o alerta de que o maior tempo de processamento pode ser prejudicial quando o fator tempo for crítico para sintonia do sistema.

A Figura 20 apresenta o desempenho de cada uma das 50 partículas da simulação PSO_4 com 150 iterações. Nesta figura, o círculo vermelho identifica a trajetória do vôo da melhor partícula ao longo das iterações. É interessante notar que apesar de haver uma forte atração em direção às melhores soluções, sempre há uma chance de as partículas buscarem novas soluções. Por isso, nota-se, por exemplo: a) que a trajetória da melhor

solução indica que, na tentativa de aprimorar a resposta, pode ocorrer que a próxima posição tenha uma solução pior que a anterior. Esta reflexão vale para as demais partículas; b) mesmo após uma elevada convergência em direção à melhor solução, ainda assim há partículas que podem continuar a investigar outras regiões de solução.

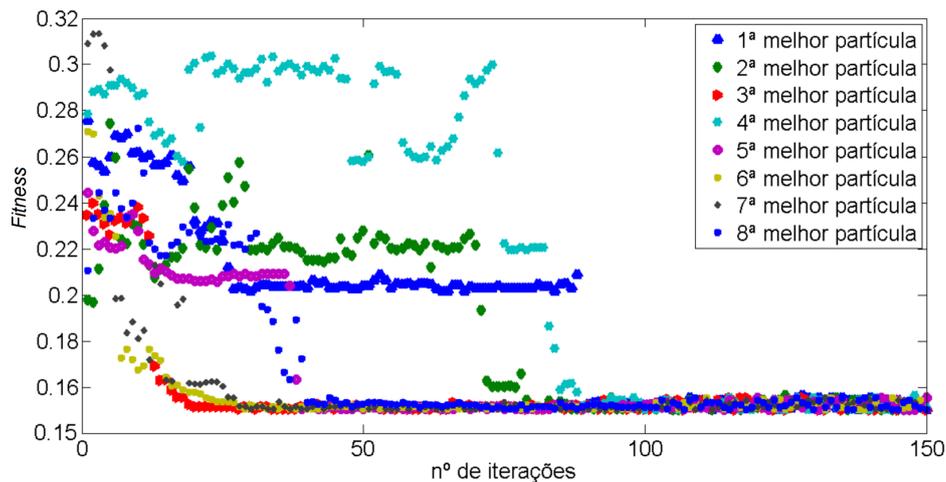
Figura 20: Espaço investigado pelo modelo PSO_4 .



Fonte: elaboração própria.

Por causa dessas características de busca por soluções, o algoritmo em questão mostra-se como uma alternativa interessante na função de sintonizar os parâmetros do otimizador em estudo. Em resumo, o PSO é um algoritmo que para esse problema: a) possui convergência com poucas iterações; b) investiga uma ampla região de busca; c) possui como característica ser reativo, isto é, a melhor partícula sempre procura uma melhor solução, e há sempre a possibilidade de uma partícula estar investigando uma solução numa região distante da melhor solução até então encontrada.

Figura 21: Desempenho da função de avaliação das oito melhores partículas do PSO_4 .



Fonte: elaboração própria.

Ainda a respeito da simulação PSO_4 , a Figura 21 apresenta a trajetória da função de avaliação das oito melhores partículas. Observa-se que, durante as 80 primeiras iterações,

um espaço de busca mais amplo é avaliado, porém, a partir da centésima iteração essas partículas são atraídas para uma FO em torno de 0,15. Sobre o trajeto que a melhor partícula percorre, verifica-se que a mesma inicialmente apresenta um desempenho igual a 0,2755, e que durante algumas iterações oscila em torno de 0,21 (ora melhorando, ora piorando), mas finalmente converge para o melhor valor encontrado de 0,1503.

As Figuras 22 e 23 apresentam, respectivamente, a trajetória de sintonia dos pesos dos gasômetros e dos queimadores, conforme solução obtida pelo método PSO na simulação PSO_4 . Nelas, estão representadas todas as soluções encontradas pelas 50 partículas ao longo de 150 iterações, estando em destaque (círculo vermelho) a trajetória de otimização da melhor partícula.

Acerca da sintonia dos pesos do gasômetro (ver Figura 22) observa-se que: a) a maioria dos pesos tiveram convergência antes da centésima iteração; b) o peso W_L^{COG} é, possivelmente, o responsável pela melhora súbita do desempenho da melhor partícula a partir da nonagésima iteração; c) diferentes combinações de sintonia produzem soluções com grande semelhança, isto é um forte indício de que é um problema com soluções múltiplas; d) apesar disto, em todos os pesos, há uma maior densidade de partículas em torno dos valores alcançados pela melhor partícula; e) alguns dos parâmetros convergem mais cedo, outros mais tarde, entretanto antes das 150 iterações já é possível admitir convergência.

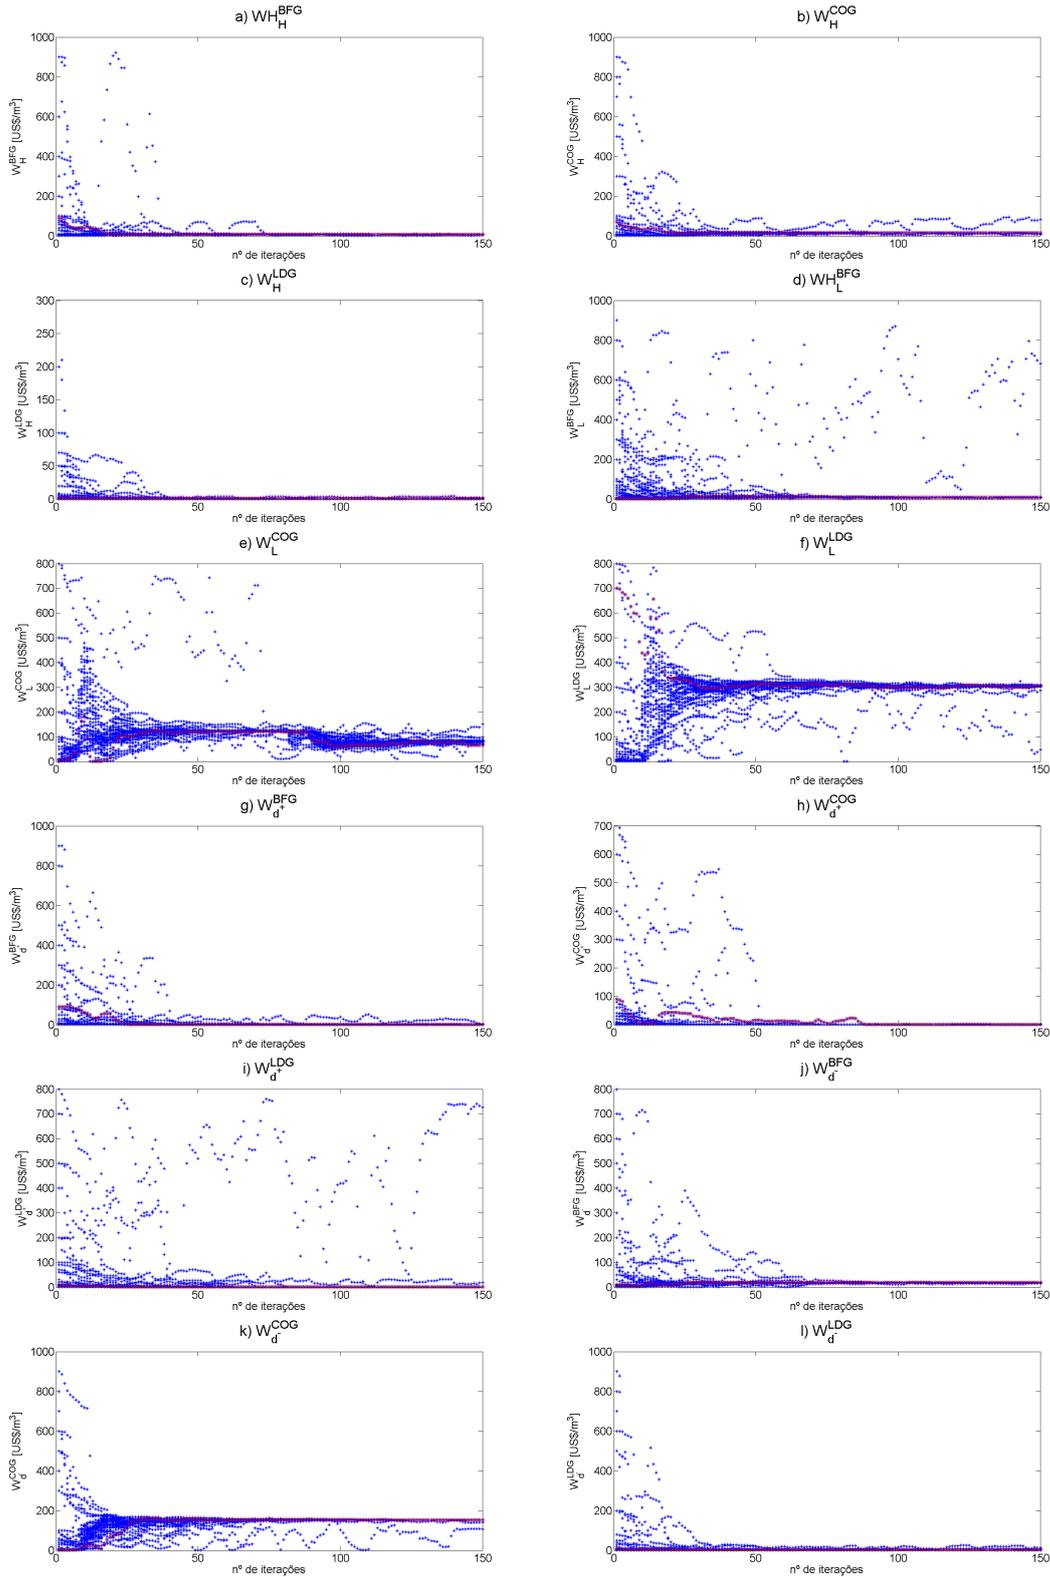
A Figura 23 permite as seguintes deduções sobre os pesos dos queimadores: a) diferentes combinações de sintonia produziram soluções semelhantes, isto é um indício de soluções múltiplas; b) mesmo assim, em todos os pesos, há uma maior densidade de partículas em torno dos valores alcançados pela melhor partícula; c) por isso, é possível pressupor convergência dos valores dos pesos dos queimadores; d) seria interessante investigar um pouco mais a relação entre os pesos W_L^{COG} e W_{SW}^{LDG} , e entre eles e a função de custo (*fitness*), pois, para a simulação em foco, os gráficos das Figuras 22 e 23 parecem sugerir que estes dois pesos foram os últimos a serem ajustados de modo a conduzir a partícula para uma posição melhor.

A Tabela 22 resume os resultados de sintonia alcançados pela melhor partícula da simulação PSO_4 . Essa combinação de pesos, produziu um custo igual a 0,1503 que é o menor custo encontrado pelo PSO nesta simulação.

Tabela 22: Parâmetros da melhor partícula do PSO_4 .

	BFG	COG	LDG	TAR
W_H	7,9212	15,6355	1,1558	-
W_L	9,5577	84,0034	308,5087	-
W_{d+}	1,9361	0,0100	0,0540	-
W_{d-}	17,9282	153,1355	3,8481	-
W_{SW}	270,3570	19,3594	148,9998	36,5451

Fonte: elaboração própria.

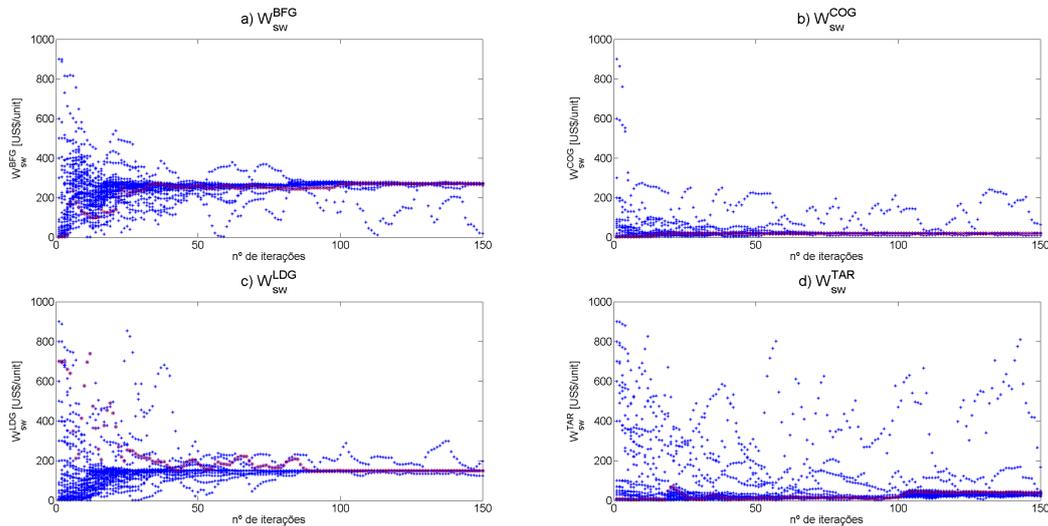
Figura 22: Ajuste dos pesos dos gasômetros via PSO_4 .

Fonte: elaboração própria.

A pesquisa realizada confirma que o PSO pode ser um método interessante na escolha dos parâmetros do modelo MILP do sistema de distribuição de gases, pois encontrou uma solução satisfatória, com poucos indivíduos e em poucas iterações. Além disso, o algoritmo tem a vantagem de gerar soluções que sempre exploram novos espaços de

busca. Ademais, pode ser usado de modo recursivo e automático pelo otimizador, o que representa uma vantagem em relação aos trabalhos precedentes. Por outro lado, ainda é demorado o processo de sintonia. Logo, é preciso pesquisar alternativas para melhorar seu desempenho, como avaliar outros ajustes para o fator de inércia, a componente cognitiva e o componente social, bem como avaliar outras meta-heurísticas.

Figura 23: Ajuste dos pesos dos queimadores via PSO_4 .



Fonte: elaboração própria.

5 *Conclusões*

A cogeração de energia é um agente importante no cenário siderúrgico, uma vez que este tipo de indústria não só é responsável pelo consumo de elevadas quantidades de insumos energéticos, como também pela geração de um volume significativo de efluentes, dentre os quais se encontram gases que têm um poder calorífico suficiente para serem utilizados como combustíveis.

Por este motivo, as usinas siderúrgicas, em especial aquelas que dominam o ciclo completo da produção de aço, ou seja, as usinas integradas, usam estes combustíveis para geração de energia térmica e eletromotriz a partir da energia química dos combustíveis. Do ponto de vista financeiro, assim como ambiental, é importante o correto gerenciamento destes recursos energéticos.

Esta tese apresenta uma solução para o problema de planejamento da distribuição dos combustíveis siderúrgicos a curto prazo, por meio de um algoritmo de controle por horizonte rolante, que executa desde previsões das séries de produção e consumo de gases, vapor de processo e eletricidade, passando pela etapa de otimização, até a etapa que realiza ajustes nos níveis dos gasômetros, de modo a corrigir erros devido às incertezas de previsão. Os modelos de previsão usados são lineares e possuem parâmetros adaptativos e o modelo de otimização é MILP multi-período. Deste modo, o algoritmo de controle resolve o problema de planejamento em tempo real.

Os parâmetros dos modelos de previsão são adaptativos, devido a não-linearidades provocadas por mudanças operacionais nas unidades da planta, e tendem a encontrar padrões como média, tendência e sazonalidade nas séries históricas de maneira que é possível prever os valores futuros da série. Assim, foi proposto o uso da estrutura ARIMA com parâmetros adaptativos para gerar previsões das séries de produção do gás de alto-forno e do gás de coqueria; e foi proposto o uso do método de Holt-Winters com parâmetros adaptativos para gerar previsões das séries de consumo dos gases de alto-forno, coqueria e aciaria, da demanda de gás misto para o processo de laminação de tiras a quente, e também para previsões das séries de demanda de vapor de processo e eletricidade.

A previsão da série temporal do gás de aciaria é a mais complicada, isto por causa da sua característica intrinsecamente intermitente, isto é, a produção ocorre em bateladas durante um pequeno intervalo de tempo. Nesse caso, como nem o método ARIMA nem Holt-Winters, ainda que tivessem parâmetros adaptativos, produziram resultados aceitáveis, foi necessário propor um procedimento heurístico. Este procedimento é uma das contribuições mais originais desta tese, tendo em vista a escassez de trabalhos com al-

guma proposta sobre a previsão do gás LDG.

Como levantado na revisão bibliográfica, há poucos trabalhos que apresentam alguma estratégia de otimização em tempo real. Nos trabalhos avaliados a partir da revisão bibliográfica, o equívoco de tentar controlar o nível dos gasômetros em torno de um valor de referência faz com que os resultados obtidos não sejam interessantes numa aplicação real. Diante disso, esta tese propôs uma estratégia de controle por horizonte rolante para resolver o problema em tempo real. Um dos propósitos dessa estratégia é a possibilidade de correção do nível dos gasômetros a partir de novas medições. Assim, toda vez em que ocorre uma rolagem, o sistema de controle faz os ajustes no nível de otimização, para corrigir o nível dos gasômetros levando em conta incertezas de previsão e não-linearidades do sistema. De acordo com esta proposta, ao invés do nível do gasômetro ser controlado num ponto de operação, foi permitido que o mesmo trabalhe em toda sua zona segura de operação. Assim, foi garantido um maior aproveitamento energético do sistema.

Simulações computacionais confirmam que erros de previsão afetam a estabilidade operacional dos gasômetros, que têm que queimar o excesso de gás quando o nível máximo de referência do gasômetro é alcançado ou restringir o fornecimento de gás quando o nível atinge a referência mínima. Outra consequência das incertezas de previsão, é a produção excedente de gás misto que resultou em queima nas torres de proteção das estações de mistura.

Entretanto, os resultados também sugerem que esses problemas podem ser reduzidos se o horizonte de controle do algoritmo rolante for reduzido, o que, por sua vez, aumenta o custo computacional. Como o tempo médio de processamento, incluindo o tempo aplicado na etapa de previsão, é menor que o período de amostragem do sistema de aquisição de dados, logo é viável que a aplicação seja implantada utilizando o horizonte de controle mínimo.

No estudo de caso apresentado, os erros de previsão não interferem significativamente na geração elétrica, pois neste caso os gases consumidos nas termoeletricas foram os gases BFG e COG, cujos modelos de previsão foram os mais precisos, isto é, apresentaram menores incertezas.

Além dos principais resultados alcançados pelo algoritmo proposto, para melhorar o desempenho do sistema de controle, foi desenvolvido um mecanismo para sintonia dos parâmetros do modelo de otimização. Este mecanismo foi desenvolvido segundo otimização por exame de partículas. Este mecanismo é uma importante inovação, pois dentre os poucos trabalhos que propõem alguma solução para sintonia dos parâmetros do otimizador, todos eles necessitam que algum especialista examine os resultados por meio de análises de sensibilidade, o que dificulta que a sintonia seja executada automaticamente. Como na sintonia dos parâmetros são usados indicadores de desempenho, foram sugeridos indicadores de desempenho normalizados e adimensionais. É importante, no entanto, que os resultados das sintonias obtidas pelo método proposto sejam validados por meio de comparações com outros métodos de sintonia.

5.1 Trabalhos futuros

Com respeito aos modelos de previsão, apesar das contribuições apresentadas nesta tese, é importante que trabalhos futuros concentrem esforços na melhoria dos modelos em tempo real, uma vez que o algoritmo de horizonte rolante com previsão perfeita apresentou menor queima nas torres de proteção do sistema de distribuição de gases, além de operar os gasômetros em regiões de maior estabilidade, que os algoritmos de horizonte rolante com erros de previsão.

Especialmente a previsão das séries de produção do gás de aciaria deve ser melhorada, pois a incerteza é grande. Neste caso, talvez fosse interessante a modelagem como um sistema de filas, segundo a qual o sopro de oxigênio poderia ser visto como a chegada de um cliente ao sistema de filas e o início da recuperação do gás seria o início do atendimento, o qual seria finalizado assim que ocorresse o fim da recuperação do gás LDG. Como consequência, pelo menos em parte, o sistema de distribuição de gases poderia ser modelado por programação dinâmica e, portanto ser resolvido por uma estratégia de controle pró-ativa cuja solução poderia produzir respostas mais estáveis, além de encontrar uma solução viável para todos os cenários considerados.

Outra alternativa a ser estudada, é a modelagem da produção do gás de aciaria como um Processo Markoviano, podendo abrir uma nova fronteira de pesquisa sobre o tema, e desta forma providenciar soluções melhores. Assim, uma das questões futuras em aberto é o desenvolvimento do algoritmo de programação dinâmica para o problema da distribuição do gás de aciaria e seu acoplamento com a estrutura MILP consoante ao problema da distribuição dos gases de alto-forno e coqueria e da produção de eletricidade e vapor de processo.

Nos estudos propostos até o momento, consideram-se fixos, enquanto ocorre as simulações, informações sobre eficiências dos equipamentos, especialmente das caldeira e turbo-geradores, e também sobre entalpias do vapor de processo. No entanto, estudos poderiam ser realizados a partir de procedimentos que realizassem novos cálculos após atualização destas informações.

Ainda há oportunidades de melhoria e outras questões devem ser estudadas de modo específico. Todavia, os principais objetivos desta tese foram alcançados e resultaram em contribuições originais que ampliam a compreensão do tema e sugerem novos horizontes de pesquisa e avaliação. Dentre os principais resultados estão: a produção de artigos científicos, em especial, (PENA; OLIVEIRA; SALLES, 2019) e (OLIVEIRA; PENA; SALLES, 2016); e o desenvolvimento tecnológico por meio de uma cooperação entre as instituições ArcelorMittal, UFES e CNPq, que culminou com a implantação de um otimizador que atualmente é usado em simulações *off-line* e testes de estratégias de operação do sistema de distribuição de combustíveis na ArcelorMittal Tubarão. Um dos motivos para que o otimizador tenha sido usado apenas em modo *off-line* é porque, nos últimos anos, o ritmo de produção da usina é máximo, de modo que o sistema opera em sua capacidade máxima, provocando queima, pois as termoelétricas não conseguem processar o montante

de gás. Porém, nos períodos em que existe um balanço equilibrado entre produção e consumo de gases siderúrgicos, mostrou-se que o algoritmo proposto permite uma geração de eletricidade entre 8 e 9% maior que a realizada pelos operadores da central termoelétrica.

Referências

- AKIMOTO, K. et al. An optimal gas supply for a power plant using a mixed integer programming model. *Automatica*, v. 27, n. 3, p. 513–518, 1991.
- AL-GHAZZAWI, A. et al. On-line tuning strategy for model predictive controllers. *Journal of Process Control*, v. 11, p. 265–284, 2001.
- ALI, E.; NOUH, A.; ZAFIRIOU, E. Optimization-based tuning non-linear model predictive control with state estimation. *Journal of Process Control*, v. 11, p. 97–107, 1993.
- ALMEIDA, G. M. de; SALLES, J. L. F. *Controle Preditivo: Sintonia e aplicações na siderurgia*. Curitiba, 2016. ISBN 978-85-8192-910-1.
- BEMPORAD, A.; MORARI, M. Control of systems integrating logic, dynamics and constraints. *Chemical Engineering Research Design*, v. 35, p. 407–427, 1999.
- BISCHI, A. et al. A rolling-horizon optimization algorithm for the long term operational scheduling of cogeneration systems. *IEEE Transactions on Automatic Control*, p. 1–18, 2017.
- BOX, G. E. P. et al. *Time Series Analysis: Forecasting and Control*. Fifth. New Jersey: John Wiley & Sons, 2015.
- CAMPONOGARA, E. et al. Distributed model predictive control. *IEEE Control Systems Magazine*, v. 22, n. 1, p. 44–52, February 2002.
- CLERC, M.; KENNEDY, J. The particle swarm - explosion, stability, and convergency in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation*, v. 6, p. 58–73, 2002.
- CREMASCO, T. R.; PENA, J. G. C.; SALLES, J. L. F. Previsão do consumo de gases combustíveis via holt-winters na usina siderúrgica integrada. *No XLVIII Simpósio Brasileiro de Pesquisa Operacional - XLVIII SBPO2016, Vitória(ES), de 27 a 30 de setembro*, p. 1316–1327, 2016.
- DIEHL, M.; AMRIT, R.; RAWLINGS, J. B. A lyapunov function for economic optimizing model predictive control. *IEEE Transactions on Automatic Control*, v. 56, n. 3, p. 703–707, 2011.
- ELLIS, M.; DURAND, H.; CHRISTOFIDES, P. D. A tutorial review of economic model predictive control methods. *Journal of Process Control*, v. 24, p. 1156–1178, 2014.
- GARCIA, C. E.; PRETT, D. M.; MORARI, M. Model predictive control: Theory and practice: a survey. *Automatica*, v. 25, n. 3, p. 335–348, 1989.
- GEN, M.; CHENG, R. *Genetic Algorithms and Engineering Optimization*. New York, 2000. ISBN 0-471-31531-1.

- GEN, M.; CHENG, R.; LIN, L. *Network Models and Optimization: Multiobjective Genetic Algorithm Approach*. London, 2008. ISBN 978-84800-180-0.
- HARJUNKOSKI, I. et al. Scope for industrial applications of production scheduling models and solution methods. *Computers and Chemical Engineering*, v. 62, p. 161–193, 2014.
- HEPPNER, F.; GRENANDER, U. A stochastic model for coordinated bird flocks. *AAAS Publications*, Washington DC, 1990.
- HILLIER, F. S.; LIEBERMAN, G. J. *Introdução à Pesquisa Operacional*. 9ª edição. ed. Brasil, 2013. ISBN 978-85-8055-118-1.
- JANAK, S. L.; FLOUDAS, C. A. Production scheduling of a large-scale industrial batch plant. i. short-term and medium-term scheduling. *Industrial and Engineering Chemistry Research*, v. 45, p. 8234–8252, 2006.
- JEONG, C. et al. Gasholder level control based on time-series analysis and process heuristics. *Korean Journal of Chemical Engineering*, v. 28, n. 1, p. 16–21, 2011.
- JIN, P. et al. The energy consumption and carbon emission of the integrated steel mill with oxygen blast furnace. *Resources, Conservation and Recycling*, v. 117, p. 58–65, 2017.
- KENDALL, G.; SU, Y. A particle swarm optimisation approach in the construction of optimal risk portfolios. *Proceedings of the 23rd IASTED International Multi-Conference Artificial Intelligence and applications*, Innsbruck Austria, 2005.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. *IEEE*, 1995.
- KENNEDY, J.; EBERHART, R. C. Swarm intelligence. *Morgan Kaufmann Publishers*, San Francisco Califórnia, 2001.
- KIM, J. H.; YI, H. S.; HAN, C. A novel milp model for plantwide multiperiod optimization of byproduct gas supply system in the iron- and steel-making process. *Chemical Engineering Research Design*, v. 81, n. 8, p. 1015–1025, September 2003.
- KIM, J. H.; YI, H.-S.; HAN, C. Plant-wide optimal byproduct gas distribution and holder level control in the iron and steel making process. *Korean Journal of Chemical Engineering*, v. 20, n. 3, p. 429–435, 2003.
- KONG, H. et al. An milp model for optimization of byproduct gases in the integrated iron and steel plant. *Applied Energy*, v. 87, n. 7, p. 2156–2163, 2010.
- KONG, H. ning. A green mixed linear programming model for optimization of byproduct gases in iron and steel industry. *Journal of Iron and Steel Research, International*, v. 22, n. 8, p. 681–685, 2015.
- KOPANOS, G. M. et al. Costs for rescheduling actions: A critical issue for reducing the gap between scheduling theory and practice. *Ind. Eng. Chem. Res.*, v. 47, p. 8785–8795, 2008.
- KOPANOS, G. M.; PISTIKOPOULOS, E. N. Reactive scheduling by a multiparametric programming rolling horizon framework: A case of a network of combined heat and power units. *Industrial and Engineering Chemistry Research*, v. 53, p. 4366–4386, 2014.

- LI, Z.; DING, R.; FLOUDAS, C. A. A comparative theoretical and computational study on robust counterpart optimization: I. robust linear optimization and robust mixed integer linear optimization. *Industrial and Engineering Chemistry Research*, v. 50, p. 10567–10603, 2011.
- LI, Z.; IERAPETRITOU, M. Process scheduling under uncertainty: Review and challenges. *Computers and Chemical Engineering*, v. 32, p. 715–727, 2008.
- LI, Z.; IERAPETRITOU, M. G. Rolling horizon based planning and scheduling integration with production capacity consideration. *Chemical Engineering Science*, v. 65, p. 5887–5900, 2010.
- MACIEJOWSKI, J. M. *Predictive Control with Constraints*. First edition. New Jersey: Prentice Hall, 2000. ISBN ISBN-13: 978-0201398236.
- MATTINGLEY, J.; WANG, Y.; BOYD, S. Receding horizon control: Automatic generation of high-speed solvers. *IEEE Control Systems Magazine*, v. 31, n. 3, p. 52–65, June 2011.
- MAYNE, D. Q. et al. Constrained model predictive control: stability and optimality. *Automatica*, v. 36, p. 789–814, 2000.
- MERKERT, L. et al. Scheduling and energy - industrial challenges and opportunities. *Computers and Chemical Engineering*, v. 72, p. 183–198, May 2015.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. *Introduction to Time Series Analysis and Forecasting*. New Jersey: John Wiley & Sons, 2008. (Wiley series in probability and Statistics).
- NEMHAUSER, G. L.; WOLSEY, L. A. *Integer and Combinatorial Optimization*. New York, 1999. ISBN 0-471-35943-2.
- OBERDIECK, R.; PISTIKOPOULOS, E. N. Explicit hybrid model-predictive control: The exact solution. *Automatica*, v. 58, p. 152–159, 2015.
- OECD/IEA. *International Energy Outlook With Projections to 2040*. Washington DC, 2016.
- OLIVEIRA JÚNIOR, V. B. de. *Otimização e controle preditivo na distribuição de combustíveis siderúrgicos*. Tese (Doutorado) — Universidade Federal do Espírito Santo, Espírito Santo, 2016.
- OLIVEIRA, V. B. de; PENA, J. G. C.; SALLES, J. L. F. An improved plant-wide multiperiod optimization model of a byproduct gas supply system in the iron and steel-making process. *Applied Energy*, November 2016.
- PENA, J. G. C. *Otimização do Sistema de distribuição de Gases Numa Usina Siderúrgica Integrada*. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, Espírito Santo, 2013.
- PENA, J. G. C.; OLIVEIRA JÚNIOR, V. B. de; SALLES, J. L. F. Análise de sensibilidade do problema de otimização do sistema de distribuição de gases numa usina siderúrgica integrada. *No XXI Congresso Brasileiro de Automática - XXI CBA2016 UFES, Vitória(ES), de 3 a 7 de outubro*, p. 194–201, 2016.

PENA, J. G. C.; OLIVEIRA JÚNIOR, V. B. de; SALLES, J. L. F. Sensitivity analysis of byproduct gas distribution optimization problem in the iron and steel-making process. *In 12th IEEE/IAS International Conference on Industry Applications - INDUSCON2016, held in Curitiba - PR, Brazil, from November 20th to 23rd, 2016.*

PENA, J. G. C.; OLIVEIRA, V. B. de; SALLES, J. L. F. Optimal scheduling of a by-product gas supply system in the iron-and steel-making process under uncertainties. *Computers and Chemical Engineering*, March 2019.

PEREIRA, R. P. A. et al. Implementation of predictive multivariable dmc controller in a pilot plant. *Latin American Applied Research Journal*, v. 44, n. 3, p. 217–224, 2014.

POLI, R. An analysis of publications on particle swarm optimisation applications. *Department of Computer Science of University of Essex, UK, 2007.*

POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimisation: an overview. *Swarm Intelligence Journal*, 2007.

QUADER, M. A. et al. A comprehensive review on energy efficient co2 breakthrough technologies for sustainable green iron and steel manufacturing. *Renewable and Sustainable Energy Reviewa*, v. 50, p. 594–614, May 2015.

REYNOLDS, C. W. Flocks, herds and schools: a distributed behavioral model. *Computer Graphics*, v. 21, n. 4, p. 25–34, 1987.

ROSSI, M.; BRUNELLI, D. Forecasting data centers power consumption with the holt-winters method. *IEEE Workshop on Environmental, Energy, and Structural Monitoring Systems (EESMS) proceedings*, Trento - Italy, 2015.

SAND, G.; ENGELL, S. Modeling and solving real-times scheduling problems by stochastic integer programming. *Computers and Chemical Engineering*, v. 28, p. 1087–1103, 2004.

SAND, G. et al. Approximation of an ideal online scheduler for multiproduct batch plant. *Computers and Chemical Engineering*, v. 24, p. 361–367, 2000.

SEBORG, D. E. et al. *Process Dynamics and Control*. 4th edition. ed. New Jersey: John Wiley & Sons, 2016. ISBN 978-1-119-28595-3.

SHAIK, M. A. et al. Production scheduling of a large-scale industrial continuous plant: Short-term and medium-term scheduling. *Computers and Chemical Engineering*, v. 33, p. 670–686, 2009.

SHAPIRO, A. et al. Risk neutral and risk averse stochastic dual dynamic programming method. *European Journal of Operational Research*, v. 224, p. 375–391, 2013.

SHI, Y.; EBERHART, R. C. A modified particle swarm optimizer. *Proceedings of the IEEE Congress on Evolutionary Computation*, Piscataway NJ, p. 69–73, 1999.

SILVENTE, J. et al. A rolling horizon approach for optimal management of microgrids under stochastic uncertainty. *Chemical Engineering Research and Design*, v. 131, p. 293–317, 2018.

SILVENTE, J. et al. A rolling horizon optimization framework for the simultaneous energy supply and demand planning in microgrids. *Applied Energy*, v. 155, p. 485–501, 2015.

- SIMON, D. *Evolutionary Optimization Algorithm: Biologically Inspired and Population-Based Approaches to Computer Intelligence*. New Jersey: John Wiley & Sons, 2013. (Wiley series in probability and Statistics).
- SINHA, G. P. et al. Strategic and operational management with optimization at tata steel. *Interfaces*, v. 25, p. 6–19, January 1995.
- WILSON, E. O. *Sociobiology: The new synthesis*. Belknap Press, Cambridge MA, 1987.
- YANG, J. hui et al. Optimization and scheduling of byproduct gas system in steel plant. *Journal of Iron and Steel Research, International*, v. 22, n. 5, p. 408–413, 2015.
- ZENG, Y. et al. A novel multi-period mixed-integer linear optimization model for optimal distribution of byproduct gases, steam and power in an iron and steel plant. *Energy*, v. 143, p. 881–899, 2018.
- ZENG, Y. jiao; SUN, Y. guang. Short-term scheduling of steam power system in iron and steel industry under time-of-use power price. *Journal of Iron and Steel Research, International*, v. 22, n. 9, p. 795–803, 2015.
- ZHANG, Q. et al. Multi-period optimal distribution model of energy medium and its application. *Journal of Iron and Steel Research International*, v. 18, n. 8, p. 37–41, 2011.
- ZHANG, X. et al. An optimal method for prediction and adjustment on byproduct gas holder in steel industry. *Expert Systems with Applications*, v. 38, n. 4, p. 4588–4599, 2011.
- ZHAO, J. et al. Hybrid neural prediction and optimized adjustment for coke oven gas system in steel industry. *IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS*, v. 23, n. 3, p. 439–449, 2012.
- ZHAO, J. et al. Effective noise estimation-based online prediction for byproduct gas system in steel industry. *IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS*, v. 8, n. 4, p. 953–963, 2012.
- ZHAO, J. et al. A mkl based on-line prediction for gasholder level in steel industry. *Control Engineering Practice*, v. 20, p. 629–641, 2012.
- ZHAO, J. et al. Data-based predictive optimization for byproduct gas system in steel industry. *IEEE Transactions on Automation Science and Engineering*, v. 14, n. 4, p. 1761–1770, October 2017.
- ZHAO, J. et al. A bayesian networks structure learning and reasoning-based byproduct gas scheduling in steel industry. *IEEE Transactions on Automation Science and Engineering*, v. 11, n. 4, p. 1149–1154, October 2014.
- ZHAO, X. et al. A milp model concerning the optimisation of penalty factors for the short-term distribution of byproduct gases produced in the iron and steel making process. *Applied Energy*, March 2015.
- ZHU, J. et al. Comparison of arima model and exponential smoothing model on 2014 air quality index in yanqing county, beijing, china. *Applied and Computational Mathematics*, v. 4, n. 6, p. 456–461, 2015.