UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA

CARLOS ROBERTO CHAVES

Implementação e comparação de performance de controladores preditivos multivariáveis M_{MPC} , estruturados com modelo de perturbação de entrada ajustados às perturbações através da utilização do modelo matemático identificado de um forno industrial petroquímico

VERSÃO CORRIGIDA

SÃO PAULO

2020

CARLOS ROBERTO CHAVES

Implementação e comparação de performance de controladores preditivos multivariáveis M_{MPC} , estruturados com modelo de perturbação de entrada ajustados às perturbações através da utilização do modelo matemático identificado de um forno industrial petroquímico

VERSÃO CORRIGIDA

Tese apresentada à Escola Politécnica da
Universidade de São Paulo para a
obtenção do título de Doutor em Ciências.

Área de Concentração:

Engenharia de Sistemas / Automação e
Controle

Orientador: Prof. Dr. Claudio Garcia

São Paulo

2020

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, ____ de ____ de ____

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Chaves, Carlos Roberto

Implementação e comparação de performance de controladores preditivos multivariáveis M_MPC, estruturados com modelo de perturbação de entrada ajustados às perturbações através da utilização do modelo matemático identificado de um forno industrial petroquímico / C. R. Chaves -- versão corr. - São Paulo, 2020.
236 p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo.
Departamento de Engenharia de Telecomunicações e Controle.

1. Identificação de Sistemas 2. Modelo de Perturbação não medida
3. Controlador Preditivo MPC 4. Análise de Desempenho 5. Algoritmo MOGA
Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Telecomunicações e Controle II.t.

DEDICATÓRIA

*Dedico a Deus, por me dares muito mais do
que eu preciso, e por me abençoares muito
mais do que eu mereço.*

AGRADECIMENTOS

Agradeço a minha mãe Zélia, ao meu pai Gercino (*in memoriam*), pela educação que me proporcionaram e pelos exemplos que tive ao longo de minha infância e adolescência.

A minha querida esposa e companheira Eliane Chaves e aos meus filhos Thiago Emanuel, Karoline e Karen, por preencherem a minha rotina diária com apoio, amor e alegria.

Aos meus irmãos Marcos, Marcio e Leila, por fazerem parte da minha vida, que Deus continue sustentando as nossas eternas ligações.

Ao meu orientador prof. Dr. Claudio Garcia, pela firme e precisa orientação, pela colaboração e oportunidade de chegar ao final deste trabalho, a cada passo de forma admirável e exemplar.

Aos professores Dr Zanin, Dr. Lincoln e Dr Darci Odloak, pela disponibilidade para orientações de maneira cortês e receptiva.

A todos os professores do curso de Pós-Graduação da Escola Politécnica da USP, pelos ensinamentos e conhecimentos transmitidos.

Aos amigos Dr. Fábio Flesch, José R. Ramos e Wellington, pelo apoio inestimável, durante este projeto, tornando a caminhada mais agradável.

Meus agradecimentos ao amigo Engº Odnei Cesar Macalossi, por oportunizar de forma decisiva, os ensaios de identificação em uma planta industrial complexa.

Ao meu amigo prof. Dr Hildebrando, pelo apoio e assertividade nos esclarecimentos, meus sinceros agradecimentos.

Aos grandes educadores, professores Dr. Gustavo Oliveira e Gideon Villar Leandro, meus sinceros agradecimentos pelo carinho e amizade.

Ao colega de coordenador de operação industrial, Ezequiel Francisco Ribas, pelo apoio e envolvimento no planejamento dos testes na unidade industrial.

Aos colegas dos grupos de turnos da operação da planta industrial do processo PETROSIX, pela disponibilidade e cordialidade durante toda a fase preparação e execução dos experimentos.

Ao colega Dr. Rodrigo Juliani, pelo apoio no processo de estimação do modelo da planta industrial.

Ao colega Dr. Mario Massa Campos e demais colegas da Petrobras que participaram de forma direta e indireta, durante a minha jornada, tornando-a mais agradável.

Às funcionárias Simone e Eliana da Secretaria de Pós-Graduação de Engenharia Elétrica da Escola Politécnica da Universidade de São Paulo, pela atenção e cordialidade nas tratativas administrativas.

Aos irmãos em Cristo Jesus, pelas orações de intersecção e palavras de motivação e vitória.

EPÍGRAFE

“Só há duas maneiras de viver a vida: a primeira é vivê-la como se os milagres não existissem. A segunda é vivê-la como se tudo fosse milagre.”

Albert Einstein

RESUMO

Na atualidade, dispõe-se de um número razoável de soluções tecnológicas para controle e otimização de sistemas ou processos multivariáveis, dentre estas tecnologias destaca-se o controle preditivo MPC. A busca pelas melhores soluções de controle para sistemas multivariáveis, através do controle preditivo, requer o conhecimento das relações de causa e efeito entre as variáveis de entrada e saída do processo. Todavia, pode-se gerar modelos dinâmicos dos processos que incluam, além das relações de causa e efeito entre as variáveis controladas e manipuladas, o efeito de perturbações não medidas. Esta particularidade do processo, poderá afetar a performance do controle preditivo quando não considerada, podendo levar, o controle da planta ou sistema, para regiões de instabilidade. A principal questão que se discute nesta tese é se a inclusão do modelo de perturbações não medidas (H) na estrutura do controlador preditivo pode melhorar o seu desempenho em relação à rejeição ou tratamento das perturbações estocásticas. Assim, esta tese visa desenvolver uma simulação e análise comparativa de desempenho entre os controladores preditivos com e sem modelo de perturbações não medidas. Os modelos do processo incluindo ou não os modelos de perturbações não medidas foram gerados a partir de dados coletados de um forno industrial de 50 MW. Os controladores MPC com e sem o modelo de perturbações não medidas foram testados através da simulação em ambiente computacional, visando uma avaliação do efeito no controle preditivo de inserir ou não esse modelo de perturbações. Ao final deste trabalho, a hipótese sobre a contribuição no desempenho do controlador preditivo com a inclusão do modelo de perturbações não medidas é confirmada através do critério IAE (integral do erro absoluto). Esse critério permite avaliar o comportamento do erro do processo obtido através da diferença entre SP (*set-point*) e PV (*process-variable*). Faz parte do escopo deste trabalho a utilização da ferramenta computacional MOGA (*Multi-Objective Genetic Algorithm*), para a otimização dos parâmetros de sintonia dos controladores preditivos com e sem o modelo de perturbações não medidas. O resultado da análise comparativa entre os controladores MPC, evidenciou através do critério IAE, que o controle preditivo MPC com modelo H , apresentou desempenho superior em relação ao controlador MPC sem modelo de perturbação não medida. Em resumo, o controle preditivo MPC com modelo de perturbação apresentou uma melhor capacidade de eliminar o erro em regime permanente, quando submetido a perturbações não medidas, permitindo que o processo opere em sua região ótima, contribuindo para a maximização da produção, redução dos índices de emissões atmosféricas e efluentes, aumento do ciclo de vida útil dos atuadores e incremento no tempo de campanha da planta industrial.

Palavras-chave: Identificação de Sistemas. Modelo de Perturbações não medidas. Controle Preditivo Multivariável. Análise de Desempenho. Algoritmo MOGA. Modelo matemático.

ABSTRACT

Currently, is a reasonable number of technological solutions for the control and optimization of multivariable systems or processes. Among these technologies the MPC predictive control stands out. The search for the best control solutions for multivariable systems through predictive control requires knowledge of the cause and effect relationships between process input and output variables. However, dynamic models of processes can be generated, including, in addition to the cause and effect relationships between controlled and manipulated variables, can be generated, the effect of non-measured disturbances. This particularity of the process may affect the performance of predictive control when not considered, and may lead, the plant to system control, to regions of instability. The main question discussed in this thesis is whether the inclusion of the model of non-measured disturbances (H) in the structure of the predictive controller can improve its performance in relation to the rejection or treatment of these stochastic disturbances. Thus, this thesis aims to develop a simulation and comparative analysis of performance among predictive controllers with and without model of non-measured disturbances. Process models including or not models of non-measured disturbances were generated from data collected from a 50 MW petrochemical furnace. MPC controllers with and without the model of non-measured disturbances were tested through simulation in a computational environment, aiming at an evaluation of the effect on predictive control of inserting or not this model of disturbances. At the end of this work, the hypothesis about the contribution in the performance of the predictive controller with the inclusion of the model of non-measured disturbances is confirmed through the result of the IAE index (*integral of the absolute error*). The IAE index allows evaluating the behavior of the error of the process obtained through the difference between SP (*set-point*) and PV (*process-variable*). In this work the Multi-Objective Genetic Algorithm (MOGA) computational tool is used, to optimize the tuning parameters of predictive controllers with and without the model of non-measured disturbances. In summary, the predictive control MPC with a perturbation model showed a better ability to eliminate the error in steady state, when subjected to unmeasured disturbances, allowing the process to operate in its optimal region, contributing to the maximization of production, reduction of indices of atmospheric emissions and effluents, increase in the life cycle of the actuators and increase in the campaign time of the industrial plant.

Keywords: System Identification. Unmeasured Disturbance Model. Multivariable Predictive Control Performance Analysis. MOGA Algorithm. Mathematical Model.

LISTA DE FIGURAS

Figura 1: Diagrama de blocos do algoritmo MPC.	30
Figura 2. – Esquema ilustrativo das estratégias do controle preditivo.	31
Figura 3 – Estrutura básica do controlador preditivo MPC.	32
Figura 4 – Diagrama esquemático usado no SDCD do forno industrial de 50 MW.	46
Figura 5– Foto do forno industrial de 50 MW.	47
Figura 6 – P&ID simplificado das malhas de controle do forno industrial.	51
Figura 7 – – Diagrama com implementação futura do controle preditivo MPC no forno industrial.	52
Figura 8 – – Fluxograma do processo de pré-identificação do modelo matemático.	58
Figura 9 - Sinais de excitação PRBS utilizado para identificação do modelo matemático do forno.	61
Figura 10- Dados obtidos do experimento de pré-identificação do forno industrial.	65
Figura 11 - Dados filtrados da variável controlada TIC-23099.	66
Figura 12 – Normalização dos dados.	67
Figura 13 – Dados reamostrados – intervalo de amostragem de 1 minuto.	68
Figura 14 - Validação dos modelos com relação à sua capacidade de predição um passo à frente.	72
Figura 15 - Predições do modelo, resposta livre.	72
Figura 16 - Erros de predição.	73
Figura 17 - Spider plot dos índices fit para diversos horizontes de predição.	73
Figura 18 – Y1 – Distribuição dos índices fit para diversos horizontes de predição.	74
Figura 19 - Y1 – Distribuição dos índices de Theil para diversos horizontes de predição.	75
Figura 20 – Y1 - Análise de correlação dos resíduos.	76
Figura 21 – Y1 - Resposta ao impulso dos resíduos.	76
Figura 22 – Y1 – Resposta em frequência dos resíduos.	77
Figura 23 - Y1 – Ganhos estacionários.	78
Figura 24 - Y1- Validação através do Error Bound.	79
Figura 25 - Y1- Mapa de polos e zeros.	80
Figura 26 - Resposta em frequência.	80
Figura 27 - Resposta ao degrau dos modelos do forno industrial.	81
Figura 28 - Y1 – Respostas ao degrau dos modelos de perturbação identificados.	81
Figura 29 - Y2 - Predições 1 passo à frente.	84
Figura 30 - Y2 - Predições infinitos passos à frente.	84
Figura 31 - Erros de predição.	85
Figura 32 - Spider plot dos índices fit para diversos horizontes de predição.	85
Figura 33 - Y2 - Distribuição dos índices fit para diversos horizontes de predição.	86
Figura 34 -Y2 - Distribuição de índices de Theil para diversos horizontes de predição.	87
Figura 35 - Y-2 - Análise de correlação dos resíduos.	88
Figura 36 - Y2- Resposta ao impulso dos resíduos.	89
Figura 37 -Y2- Resposta em frequência dos resíduos.	89
Figura 38 -Y2- Ganhos estacionários.	90
Figura 39 -Y2- Validação Error Bound.	91
Figura 40 - Y2- Mapa de polos e zeros.	91
Figura 41 -Y2- Resposta em frequência dos modelos identificados.	92
Figura 42 -Y2 – Resposta ao degrau dos modelos de processo identificados.	93
Figura 43 - Y3 – Predições 1 passo à frente.	94
Figura 44 - Y3- Simulação livre.	95
Figura 45 - Y3- Erros de predição.	95
Figura 46 -Y3 -Spider plot dos índices fit para diversos horizontes de predição.	96
Figura 47- Y3 – Distribuição dos índices fit para diversos horizontes de predição.	96
Figura 48- Y3 – Distribuição dos índices de Theil para diversos horizontes de predição.	97
Figura 49- Y3 - Análise de correlação dos resíduos.	98
Figura 50 - Y3 - Resposta ao impulso dos resíduos.	98
Figura 51 - Y3 - Resposta em frequência dos resíduos.	99
Figura 52 -Y3-Validação Error Bound.	100

Figura 53 - Y3 - Mapa de polos e zeros.	101
Figura 54 - Y3 - Resposta em frequência do modelo identificado.	101
Figura 55 - Y3 - Resposta ao degrau dos modelos de processo identificados.	102
Figura 56- Y3 - Resposta ao degrau dos modelos de perturbação identificados.	103
Figura 57 . Dados da variável de processo TIC-23099.	112
Figura 58. Dados da variável de processo AIC-23001.	113
Figura 59. Dados da variável de processo PIC-23039.	113
Figura 60. Dados do set-point da FIC-23027.	114
Figura 61 . Dados do set-point da FIC-23028.	114
Figura 62. Dados do set-point da FIC-23025.	115
Figura 63. Dados do set-point da vazão de gás de processo (FIC-23003), uma perturbação medida.	115
Figura 64 - Dados normalizados das variáveis controladas.	116
Figura 65 - Dados normalizados das variáveis manipuladas.	117
Figura 66 - Dados reamostrados das variáveis controladas.	118
Figura 67 - Dados reamostrados das variáveis manipuladas.	118
Figura 68 - Zoom de uma interpolação realizada pelo comando filloutliers.	119
Figura 69. Comparação entre modelo identificado e dados coletados para predição infinitos passos à frente da TIC-23099.	122
Figura 70. Comparação do modelo e dos dados coletados para predição infinitos passos à frente para a AIC-23001.	123
Figura 71. – Comparação do modelo e dos dados coletados para predição dez passos à frente para a	124
Figura 72. Resposta ao degrau unitário dos modelos identificados.	126
Figura 73. Respostas a degraus aplicados na planta e no modelo identificado para a TIC-23099.	127
Figura 74. Respostas a degraus aplicados na planta e o modelo identificado para a AIC-23001.	128
Figura 75 - Respostas a degraus aplicados na planta e no modelo identificado para a TIC-23099.	128
Figura 76 - Análise da autocorrelação dos resíduos e da correlação cruzada dos resíduos com as entradas.	129
Figura 77 - Mapa de polos e zeros do sistema identificado.	130
Figura 78 - Estrutura dos modelos de planta, perturbações e ruído do MPC do MATLAB.	132
Figura 79 - Estrutura dos modelos de planta, perturbações e ruído do MPC do MATLAB.	135
Figura 80 - Topologia básica do filtro de Kalman.	137
Figura 81 - Fronteira de Pareto.	147
Figura 82 - Plotagem da fronteira de Pareto.	149
Figura 83 - Entradas do MMPC e do MMPCopt.	150
Figura 84 Saídas do MMPC e do MMPCopt.	150
Figura 85 Saídas do MMPC e do MMPCopt.	151
Figura 86 Saídas do MMPC e do MMPCopt.	151
Figura 87 - Controlador MPC com modelo H para a análise da perturbação de entrada.	155
Figura 88-Modelo proposto para a análise da perturbação de entrada.	156
Figura 89 - Resposta de rejeição a perturbação da TIC-23099 – MPC com e sem modelo de perturbação.	158
Figura 90 - Resposta da rejeição à perturbação na AIC-23001 - MPC com e sem modelo de perturbação.	159
Figura 91 - Resposta de rejeição à perturbação na PIC-23039 – MPC com e sem modelo de perturbação.	159
Figura 92 - Resposta das variáveis manipuladas a MPC com e sem modelo H.	160
Figura 93 - Curva de resposta a perturbação – TIC-23099.	161
Figura 94 - Curva de resposta a perturbação – AIC-23001.	162
Figura 95 - Curva de resposta a perturbação – PIC-23039.	163
Figura 96 - Curva de resposta de rejeição a perturbação com mudança de set-point – TIC-23099.	164
Figura 97 - Curva de resposta a perturbação com mudança de set-point – AIC-23001.	164
Figura 98 - Curva de resposta a perturbação com mudança de set-point – PIC-23039.	165
Figura 99 Resposta do controlador MMPC a distúrbios constantes – TIC-23099.	166
Figura 100 Resposta do controlador MMPC a distúrbios constantes – AIC-23001.	166
Figura 101 Resposta do controlador MMPC a distúrbios constantes – PIC-23039.	167
Figura 102 Resposta do controlador MMPC a distúrbios constantes – variáveis manipuladas.	167
Figura 103 Critério IAE do controlador MMPC com e sem modelo H com distúrbios constantes.	168
Figura 104 – Resposta da TIC-23099 às perturbações com o controlador MPC com e sem modelo H.	169
Figura 105 – Resposta da AIC-23001 às perturbações com o controlador MPC com e sem modelo H.	169
Figura 106 – Resposta da PIC-23039 às perturbações com o controlador MPC com e sem modelo H.	170

<i>Figura 107 – Diagrama de blocos do Filtro de Kalman para perturbações não medidas, controle avançado PACE.</i>	<i>198</i>
<i>Figura 108 – Arquitetura do Sistema Digital de Controle Yokogawa com Interface APC.</i>	<i>199</i>
<i>Figura 109 – – Advanced Identification, Data Analysis and Controller Design.</i>	<i>199</i>
<i>Figura 110 – Topologia cliente –servidor para aplicações do controle avançado SICON.</i>	<i>202</i>
<i>Figura 111 – Arquitetura do Sistema de controle SICON e fluxo de dados entre as aplicações.</i>	<i>204</i>
<i>Figura 112 – Bloco do Controlador Preditivo MPC – Biblioteca DeltaV –SDCD.</i>	<i>206</i>
<i>Figura 113 – Diagrama de Blocos do Controlador MPC da Emerson Process.</i>	<i>207</i>
<i>Figura 114 – Conectividade do Controle Preditivo Honeywell com interfaces comerciais.</i>	<i>208</i>
<i>Figura 115 – Interface de modelagem do controle preditivo Honeywell – Profit Design Studio.</i>	<i>209</i>
<i>Figura 116 – Diagrama de blocos da estrutura interna do APC Honeywell.</i>	<i>210</i>
<i>Figura 117 – Diagrama de blocos dos componentes do controle preditivo 3dMPC.</i>	<i>212</i>
<i>Figura 118 – Diagrama de blocos do Controlador 3dMPC – ABB.</i>	<i>213</i>
<i>Figura 119 - O Algoritmo da Função minimização custo – Pavilion8® - Rockwell Automation.</i>	<i>215</i>
<i>Figura 120- Arquitetura do MPC Pavilion8® - Rockwell Automation.</i>	<i>216</i>
<i>Figura 121 – Evolução da Inovação do Controlador Aspen MPC.</i>	<i>219</i>
<i>Figura 122. - Perfil geológico da mina de xisto betuminoso em São Mateus do Sul, Paraná.</i>	<i>222</i>
<i>Figura 123 – Mineração de xisto pelo método em tiras.</i>	<i>223</i>
<i>Figura 124 - Minério de xisto - Formação de Irati.</i>	<i>224</i>
<i>Figura 125 – Mecanismo de britagem primária.</i>	<i>225</i>
<i>Figura 126 – Unidade de Tratamento de Minério, processo de classificação do xisto.</i>	<i>226</i>
<i>Figura 127 – Retorta: reator de xisto, processo de pirólise.</i>	<i>227</i>
<i>Figura 128 – Retorta – Processamento de xisto.</i>	<i>227</i>
<i>Figura 129 - Topo do reator, entrada de xisto para Processamento.</i>	<i>228</i>
<i>Figura 130 – Parte inferior da retorta, onde é retirado o xisto retornado.</i>	<i>229</i>
<i>Figura 131 – Precipitador Eletrostático e vaso condensador e separador de interface óleo-agua.</i>	<i>231</i>
<i>Figura 132 – Compressor axial, fabricante Sulzer.</i>	<i>234</i>
<i>Figura 133 – Compressor Axial Sulzer– responsável pela dinâmica do gás do processo.</i>	<i>234</i>
<i>Figura 134 - Processo Petrosix Forno Industrial e Retorta.</i>	<i>235</i>

LISTA DE TABELAS

<i>Tabela 1 - Variáveis controladas do processo de geração de energia térmica do forno industrial.</i>	<i>48</i>
<i>Tabela 2 - Variáveis manipuladas do processo de geração de energia térmica do Forno Industrial.</i>	<i>48</i>
<i>Tabela 3 - Perturbação medida.</i>	<i>48</i>
<i>Tabela 4 – Dados normalizados do conjunto de variáveis em torno do ponto de operação.</i>	<i>67</i>
<i>Tabela 5 - Matriz de correlação das variáveis do processo.</i>	<i>69</i>
<i>Tabela 6 -Ponto de operação do modelo.</i>	<i>104</i>
<i>Tabela 7- Comparação entre os sinais de excitação tipo degrau e PRBS.</i>	<i>108</i>
<i>Tabela 8. Parâmetros de planejamento para a excitação da planta com sinais PRBS.</i>	<i>110</i>
<i>Tabela 9. Variáveis coletadas no experimento.</i>	<i>111</i>
<i>Tabela 10. Tempos de chaveamento para respeitar os tempos de acomodação.</i>	<i>111</i>
<i>Tabela 11. Conformidade às restrições de aplicação do PRBS.</i>	<i>112</i>
<i>Tabela 12. Teste da hipótese de nenhuma correlação – p-valores.</i>	<i>120</i>
<i>Tabela 13. Valores nominais das variáveis usadas para a identificação.</i>	<i>120</i>
<i>Tabela 14. Parâmetros usados na identificação com estrutura ARMAX.</i>	<i>121</i>
<i>Tabela 15 - Matriz de ganhos da variável PIC-23039.</i>	<i>124</i>
<i>Tabela 16. Matriz de ganhos dos modelos identificados.</i>	<i>126</i>
<i>Tabela 17 - Valores absolutos dos autovalores do modelo identificado.</i>	<i>130</i>
<i>Tabela 18 - Variáveis do MPC do MATLAB.</i>	<i>133</i>
<i>Tabela 19 – Parâmetros iniciais do MPC-MATLAB™.</i>	<i>134</i>
<i>Tabela 20 – Valores nominais das variáveis de saída – (variáveis controladas).</i>	<i>148</i>
<i>Tabela 21 - Valores de escala e de ganho para as variáveis manipuladas e controladas.</i>	<i>149</i>
<i>Tabela 22 – Valores do critério IAE para a planta sem e com sintonia do controlador.</i>	<i>152</i>
<i>Tabela 23 - Resultados da integral do esforço IAU para os atuadores do forno.</i>	<i>152</i>
<i>Tabela 24 – Valor do critério IAE da rejeição à perturbação.</i>	<i>160</i>
<i>Tabela 25 – Critério IAE da rejeição à perturbação para a TIC-23099.</i>	<i>161</i>
<i>Tabela 26 – Critério IAE da rejeição à perturbação para a AIC-23001.</i>	<i>162</i>
<i>Tabela 27 – Critério IAE da rejeição à perturbação para a PIC-23039.</i>	<i>163</i>
<i>Tabela 28 – Critério IAE da rejeição à perturbação para a PIC-23039.</i>	<i>165</i>
<i>Tabela 29 - Faixa das variâncias das perturbações injetadas nos três canais de perturbações não medidas de entrada.</i>	<i>168</i>
<i>Tabela 30 - Médias e desvios-padrão dos resultados das simulações do controlador MPC com e sem H.</i>	<i>170</i>
<i>Tabela 31– Ferramentas computacionais do SDCD DeltaV -Emerson Process</i>	<i>205</i>
<i>Tabela 32 – Fluxo do Ciclo de vida da Solução do Controle Preditivo Honeywell.</i>	<i>210</i>

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AI	<i>Artificial Intelligence</i>
AIC	<i>Analysis Indicator Controller</i>
AINDA	<i>Advanced Identification and Data Analysis</i>
APC	<i>Advanced Process Control</i>
ARMAX	<i>AutoRegressive Moving Average with Exogenous variable</i>
ARX	<i>AutoRegressive with Exogenous Variable</i>
ASYM	Método Assintótico
BIC	<i>Bayesian Information Criterion</i>
BJ	Box-Jenkins
CDF	<i>Cumulative Distribution Function</i>
CPM	<i>Control Performance Monitor</i>
CSTR	<i>Continuous Stirred Tank Reactor</i>
CV	<i>Controlled Variable</i>
DCS	<i>Digital Control System</i>
DV	<i>Disturbance Variable</i>
EKF	<i>Extended Kalman Filter</i>
FIC	<i>Flow Indicator Controller</i>
FIR	<i>Finite Impulse Response</i>
FV	<i>Flow Valve</i>
GPC	<i>Generalized Predictive Control</i>
IHMPC	<i>Infinite Horizon Model Predictive Control</i>
KF	<i>Kalman Filter</i>
IMC	<i>Internal Model Controllers</i>
SMPC	<i>Simplified Model Predictive Control</i>
ITAE	<i>Integral of Time and Absolute Error</i>
LCPI	Laboratório de Controle de Processos Industriais
LDMC	<i>Linear Dynamics Matrix Control</i>
LMIs	<i>Linear Matrix Inequalities</i>
LP	<i>Linear Process</i>
MAC	<i>Model Algorithmic Control</i>

MBPC	<i>Model Based Predictive Controller</i>
MIMO	<i>Multiple Input – Multiple Output</i>
MISO	<i>Multiple Input - Single Output</i>
MOGA	<i>Multi-Objective Genetic Algorithm</i>
MPC	<i>Model Predictive Control</i>
M_{MPC}	<i>MATLAB - Model Predictive Control</i>
MPHC	<i>Model Predictive Heuristic Control</i>
MSE	<i>Mean Squared Error</i>
MV	<i>Manipulated Variable</i>
NMPC	<i>Non-linear Model Predictive Control</i>
ODBD	<i>Open Data Base Connectivity</i>
OE	<i>Output Error</i>
OPC	<i>OLE for Process Control</i>
OPOM	<i>Output Prediction Oriented Model</i>
P&D	<i>Pesquisa e Desenvolvimento</i>
P&ID	<i>Piping and Instrumentation Diagram</i>
PACE	<i>Platform for Advanced Control and Estimation</i>
PCWS	<i>Process Control Web Server</i>
PSO	<i>Particle Swarm Optimization</i>
PI	<i>Plant Information</i>
PIC	<i>Pressure Indicator Controller</i>
PID	<i>Proporcional; Integral; Derivativo</i>
POV	<i>Process Output Variables</i>
PV	<i>Pressure Valve</i>
QDMC	<i>Quadratic Dynamic Matrix Control</i>
QF	<i>Quadratic Function</i>
QP	<i>Quadratic Programming</i>
RE	<i>Reator de Xisto</i>
RF	<i>Robustness Factor</i>
RMPCT	<i>Robust Multivariable Predictive Control Technology</i>
ROSSMPC	<i>Reduced Order State-Space MPC</i>
SDCD	<i>Sistema Digital de Controle Distribuído</i>
SICON	<i>Sistema de Controle Preditivo da PETROBRAS</i>
SISO	<i>Single Input Single Output</i>

SMPC	<i>Stochastic Model Predictive Control</i>
SMS	Saúde, Segurança e Meio Ambiente
TI	<i>Temperature Indicator</i>
TIC	<i>Temperature Indicator Controller</i>
UPI	Unidade Protótipo de Irati
ZOH	<i>Zero-Order Hold</i>

LISTA DE SÍMBOLOS E ABREVIações

A, B_u, B_v, C e D_v	Constantes do observador de estados
A_{id}, B_{id}, C_{id} e D_{id}	São matrizes constantes no espaço de estados
$B(u), B(v), u(k)$ e $v(k)$	Colunas do parâmetro B do observador correspondentes às entradas
C_3	Gás propano
C_m	Linhas do observador de parâmetros C, correspondentes às saídas medidas da planta
d_k	Perturbação com ruído branco
D_{mv}	Linhas e colunas do parâmetro do observador D, correspondentes às saídas da planta e perturbações medidas
f	Frequência [Hz]
H	Modelo da perturbações não medidas
L, M	Matrizes constantes dos ganhos de Kalman
p	Horizonte de predição
q	Operador de deslocamento, $q^{-1}y(k) = y(k - 1)$
$r_j(k + 1 k)$	Valores de referência para a saída da planta
s	Operador matemático em tempo contínuo, $s=j\omega$
S_o	Matriz diagonal dos ganhos de saída em unidades de engenharia
S_i	Matriz diagonal dos ganhos de entrada em unidades de engenharia
s_j^y	Fator de escala para a j -ésima saída, em unidades de engenharia
t_s	Tempo de acomodação
u	Média de um conjunto de valores
$u^{act}(k - 1)$	MV aplicada na planta de $k - 1$ a k
$u^{opt}(k - 1)$	MV ótimo recomendado pelo MPC
u_p	Vetor adimensional das variáveis de entrada da planta
$v(k)$	Perturbações atuais medidas
$w_{i,j}^y$	Ganhos adimensionais de sintonia para a j -ésima saída
x	Variáveis de decisão

x_c	Vetor de estados do modelo da planta
$x_c(k k)$	Estimações dos estados do controlador
$x_c^T(k)$	Vetor de estados
x_{id}	Vetor de estados do modelo de perturbação de entrada
x_{od}	Vetor de estados do modelo de perturbação de saída
x_p	Vetor de estados da planta em unidades de engenharia
$x_c(k k-1)$	Estimação do estado do controlador
x_n	Vetor de estados do modelo de ruído branco
z	operador matemático em tempo discreto, $z = e^{j\omega T}$
$x(n) * h(n)$	Produto de convolução finita dos sinais discretizados
$y_j(k+1 k)$	Saídas previstas da planta
$y_m(k)$	Saídas medidas atuais da planta
y_p	Vetor adimensional das variáveis de saída da planta
$\varepsilon(t)$	Erro de predição
σ	Desvio padrão
σ^2	Variância
T	Constante de tempo
ω	Frequência [rad/s]
ω_c	Frequência de corte
ω_{cn}	Frequência de corte normalizada
ω_p	Frequência de passagem
ω_s	Frequência de rejeição

SUMÁRIO

CAPÍTULO 1	23
Introdução	23
1.1 Contextualização	23
1.2 Revisão Bibliográfica	26
1.2.1 Controle Preditivo	Erro! Indicador não definido.
1.2.2 Controle Preditivo Multivariável Baseado em Modelo	31
1.2.3 Controle Preditivo MPC com Modelo em Espaço de Estados	35
1.2.4 Controle Preditivo com Modelo de Perturbações Não medidas	36
1.3 Motivação	38
1.4 Objetivos	42
1.5 Contribuições	43
1.6 Estrutura Do Trabalho	43
CAPÍTULO 2	45
Planta Industrial – XISTO	45
2.1 O Forno Industrial de 50 MW	45
2.2 Malhas de controle do Forno Industrial	48
2.3 Malha de controle de temperatura do gás de processo	49
2.2.2 Malha de controle da concentração de oxigênio nos gases de combustão	53
2.2.3 Malha de controle da pressão do tronco de gás combustível	53
2.2.4 Variáveis de perturbação medidas e não medidas	54
CAPÍTULO 3	55
Preparação para os Testes de Pré-Identificação e Identificação do Modelo	55
3.1 Planejamento do Experimento de Pré-Identificação	55
3.1.1 Pré-identificação com Sinal Excitação do Tipo Degrau	59
3.2 Planejamento do Experimento de Identificação do Forno Com Sinais <i>PRBS</i>	59
CAPÍTULO 4	63
Pré-Identificação	63
4.1 Pré-identificação do Forno Industrial	63
4.2 Execução do Experimento De Identificação	63
4.3 Tratamento dos Dados	64
4.3.1 Filtragem dos Dados Coletados	65
4.3.2 Normalização dos Dados	66
4.3.3 Reamostragem dos Dados Identificados	68
4.4 Análise de Correlação das Variáveis	69
4.5 Pré-Identificação do Modelo da Variável Y-1 TIC-23099	70

4.5.1	Validação dos Modelos da Variável Y-1 TIC-23099	70
4.5.2	Validação de Theil dos modelos da Variável Y-1 TIC-23099	74
4.5.3	Análise de Resíduos dos modelos da Variável Y-1 TIC-23099	75
4.5.4	Análise de Ganhos dos modelos da Variável Y-1 TIC-23099	77
4.5.5	Validação pelo <i>Error Bound</i> dos modelos da Variável Y1 TIC-23099	78
4.5.6	Mapa de Polos e Zeros dos modelos da Variável Y-1 TIC-23099	79
4.5.7	Resposta em Frequência dos modelos da Variável Y-1 TIC-23099	80
4.5.8	Resposta ao Degrau dos modelos da Variável Y-1 TIC-23099	81
4.6	Pré-Identificação do Modelo da Variável Y-2 PIC-23039	82
4.6.1	Validação dos Modelos da Variável Y-2 PIC-23039	82
4.6.2	Validação de Theil dos Modelos da Variável Y-2 PIC-23039	86
4.6.3	Análise de Resíduos dos Modelos da Variável Y-2 PIC-23039	87
4.6.4	Análise dos Ganhos estacionários dos Modelos da Y-2 PIC-23039	90
4.6.5	Validação <i>Error Bound</i> dos Modelos da Variável Y-2 PIC-23039	90
4.6.6	Mapa de Polos e Zeros dos Modelos da Variável Y-2 PIC-23039	91
4.6.7	Resposta em Frequência dos Modelos da Variável Y-2 PIC-23039	92
4.6.8	Resposta ao Degrau dos Modelos da Variável Y-2 PIC-23039	92
4.7	Pré-Identificação do Modelo da Variável Y3 – AIC-23001	94
4.7.1	Validação FIT do Modelo da Variável Y3 – AIC-23001	94
4.7.2	Validação de Theil do Modelo da Variável Y3 – AIC-23001	97
4.7.3	Análise de Resíduos do Modelo da Variável Y3 – AIC-23001	97
4.7.4	Análise de Ganhos no Estado Estacionário do Modelo da Variável Y3 – AIC-23001	99
4.7.5	Validação através do <i>error bound</i> do Modelo da Variável Y3 – AIC-23001	100
4.7.6	Mapa de Polos e Zeros do Modelo da Variável Y3 – AIC-23001	100
4.7.7	Resposta em Frequência do Modelo da Variável Y3 – AIC-23001	101
4.7.8	Resposta ao Degrau do Modelo da Variável Y3 – AIC-23001	102
4.8	Modelo Matemático do Forno Industrial da Petrosix®	103
CAPÍTULO 5		106
identificação dos Modelos com Sinais PRBS		106
5.1	Motivação para Utilização do Sinal PRBS	106
5.2	Preparação do Experimento	109
5.3	Realização do Experimento	111
5.4	Dados Brutos Coletados	112
5.5	Tratamento dos Dados	116
5.5.1	Normalização	116
5.5.2	Reamostragem	117

5.5.3	Remoção de <i>Outliers</i>	119
5.5.4	Matriz de Correlação	120
5.6	Identificação do Modelo	120
5.6.1	Identificação da TIC-23099	121
5.6.2	Identificação da AIC-23001	122
5.6.3	Identificação da PIC-23039	123
5.6.4	Resultado Completo da identificação	125
5.6.5	Repostas ao Degrau dos modelos obtidos	127
5.7	Análise da Estabilidade do Modelo Identificado	129
5.8	Modelo de Perturbação Não Medida	131
CAPÍTULO 6		132
Implementação e Sintonia do Controlador MPC		132
6.1	Implementação do Controlador MPC	132
6.1.1	Modelagem do Controlador MPC	134
6.1.2	Predição dos Estados das variáveis Através do Filtro Kalman	135
6.2	Modelo de Predição no Controlador MPC	138
6.2.5	Observador de Estados	138
6.2.6	Cálculo dos Ganhos de Kalman no Estado Estacionário	141
6.2.7	Predição das Variáveis de Saída	141
6.2.8	Problema de Otimização	142
6.2.9	Geração dos Sinais das Perturbações e Ruídos	143
6.2.10	Implementação do Modelo no MATLAB™	144
6.2.11	Criação do MPC no MATLAB™	145
6.3	Sintonia do Controlador MPC	145
CAPÍTULO 7		153
Comparação Entre MPC Com e Sem Modelo H		153
7.1	Comprovação Teórica	153
7.2	Modelo de Perturbação	154
7.3	Comparação dos $MMPC$ com e sem Modelo H	157
7.3.1	Rejeição à Perturbação	158
7.3.2	Rejeição à perturbação com Mudança de <i>Set-point</i>	163
7.3.3	Rejeição a Distúrbio Constante	165
7.4	Análise Ampliada dos Controladores MPC com e sem Modelo H	168
7.5	Conclusão da Comparação	171
CAPÍTULO 8		173
Conclusões		173
8.1	Sugestões para Trabalhos Futuros	174
Referências Bibliográficas		175
A.I - Criação do Controlador MPC com e Sem Modelo de Perturbação		183
A.II - Criação e Identificação do Modelo da Planta		184

A.III - Criação das Referências	186
A.IV - Simulação da Planta com Perturbação não medida de Entrada com Modelo H	187
A.V - Simulação da Planta com Perturbação não medida	189
A.VI - Otimização MOGA	190
A.VII - Plotagem dos Resultados	191
A.VIII - Simulação da Planta	193
A.IX - Modelo da Planta Aumentado	195
Apêndice B	197
B.I - Controladores Preditivos Multivariáveis Comerciais	197
B.II - Controlador Preditivo Multivariável- PACE Yokogawa	197
B.III - Sistema de controle - Sicon	200
B.IV - Controlador DeltaV Predict™	204
B.V - Honeywell Robust MPC Technology	207
B.VI - Multivariable Control for Industries 3dMPC® - ABB	211
B.VII - Pavilion8® Model Predictive Control	214
B.VIII - Aspen DMC3™ Controle Preditivo	217
B.IX - Considerações Sobre MPC Comerciais	219
C.I - Oil Shale Xisto	221
C.II - Sistema de Tratamento de Minério	223
C.III - O Processo Petrosix®	226
C.IV - Variáveis Operacionais do Processo de Retortagem	232
C.V - Compressor Axial	233
D. I. Contribuição acadêmica	236

CAPÍTULO 1

INTRODUÇÃO

Neste capítulo são apresentadas as principais fundamentações e premissas para o desenvolvimento desta tese, tais como: a motivação, objetivos propostos e contribuições na área de Controle Preditivo Multivariável e Identificação de Sistemas, conforme descrito nas Seções 1.1 a 1.4. Na Seção 1.5 consta a revisão bibliográfica e na Seção 1.6 é apresentada a organização dos capítulos desta tese.

1.1 CONTEXTUALIZAÇÃO

Em função das características dinâmicas e sazonalidade do mercado de commodities, torna-se imperativo que as empresas do segmento de petróleo e gás disponibilizem investimentos para a prospecção de novas soluções para problemas de controle e otimização de processos, que propiciem a maximização da produção, diminuição do consumo de energia, manutenção da conformidade legal, restrições operacionais, sustentabilidade ambiental e desenvolvimento socioeconômico (PERISSÉ, 2007).

Os aspectos econômicos relacionados com a variação do preço e da produção mundial de petróleo, impõem um impacto direto na oferta de derivados no mercado consumidor. Os aspectos destacados, corroboram para a necessidade de uma adaptação rápida das unidades produtivas, em resposta às restrições mercadológicas que são: restrições ambientais, perfil geológico da localização do petróleo em águas profundas e fontes alternativas de energia renováveis em substituição aos combustíveis (CORRÊA, 2009)

Desde o início da Revolução Industrial, no século XVIII, o controle de processos tem ocupado um papel de destaque no desenvolvimento de novas metodologias e técnicas para tornar factível a otimização com eficiência de processos industriais. Para atender aos objetivos explicitados no parágrafo anterior, se faz necessário incorporar novas tecnologias de controle e otimização de processos, de modo a propiciar o replanejamento estratégico da produção de derivados de petróleo, em resposta às demandas de mercado (JONES; PUJADÓ, 2006).

Todavia, um sistema de controle e otimização de processos deve manter a planta operando eficientemente, em uma determinada faixa de operação desejada, rejeitando o efeito de perturbações e garantindo a qualidade do produto (ÅSTRÖM; HÄGGLUND, 1995). Em termos práticos, todos os processos são submetidos a perturbações e restrições, limites da faixa de atuação e taxa de variação do curso dos elementos finais de controle.

Na prática, os pontos de operação das plantas são determinados de modo a satisfazer determinadas metas econômicas e estão na interseção de certas restrições. Além da capacidade inerente do sistema de controle em atender as especificações operacionais, o sistema regulatório deverá ser capaz de lidar com restrições, otimização, sem transpor os indicadores de disponibilidade e confiabilidade da planta (ZHU, 2001).

Nos últimos anos, a indústria de petróleo, estimulada pela necessidade de redução de custos operacionais, adequação das especificações técnicas de produtos em conformidade com as novas regulamentações ambientais, tem buscado incentivar iniciativas de pesquisa e desenvolvimento em novas tecnologias para o controle e otimização da produção (CAMPOS; TEIXEIRA, 2006). Atualmente, dispõem-se de diversas alternativas tecnológicas que oferecem soluções customizadas para a implementação do controle e otimização de processos. A seleção correta e apropriada dos métodos e estratégias para controle e otimização de processos, aderentes à dinâmica da planta, contribuiu significativamente para o aumento da competitividade, frente às mudanças do mercado nacional e internacional de derivados de petróleo e gás (ROFFEL; BETLEM, 2006).

Este novo cenário, requer do projetista de sistemas de controle e otimização, um conhecimento prévio do modelo matemático da dinâmica do processo, de maneira a atender a função objetivo, relacionada com a maximização da produção, restrições operacionais e estabilização da planta. Além disso, outros objetivos devem ser contemplados no sistema de controle e otimização, tais como (AGUIRRE, 2015):

1. Obtenção de uma determinada resposta transiente;
2. Rejeição de ruído de medição e perturbações não medidas;
3. Melhoria no erro de estado estacionário; e
4. Robustez a variações dos parâmetros da planta.

Através deste novo cenário competitivo, surge a motivação para a utilização do controle avançado. O controle avançado, ao contrário do controle clássico, consegue reunir as características e funcionalidades necessárias para satisfazer os critérios de robustez, otimização econômica e lidar com restrições. A aplicação do controle preditivo tem se tornando frequente na indústria de petróleo.

Por outro lado, para o desenvolvimento do controle avançado é necessário possuir o conhecimento prévio da dinâmica do processo ou modelo matemático (KANO; OGAWA, 2009). Faz parte da estrutura do algoritmo do controle preditivo, os modelos matemáticos do processo. Com base neste modelo, são calculadas as predições das ações de controle futuras e otimização da função objetivo (função custo).

O modelo matemático, por sua vez, deve ser representativo em relação ao comportamento dinâmico do sistema real. Desta maneira, o sucesso da implementação do controle avançado depende da representatividade do modelo com relação às características da dinâmica do sistema real, isto é, o modelo matemático deve reunir o máximo de informações que possam corroborar com a melhoria do algoritmo para predições de ações futuras e otimização do processo. Todavia, observa-se que os modelos matemáticos têm uma característica básica: explicitar as relações entre as variáveis que são quantidades físicas bem definidas e, além disso, essa quantidade muitas vezes pode ser medida por algum instrumento ou dispositivo (AGUIRRE, 2004). Ainda de acordo com Aguirre (2004), a identificação de sistemas, por ser a área do conhecimento que estuda maneiras de modelar e analisar sistemas a partir de observações, é recomendada como uma ferramenta a ser utilizada para estimar modelos dinâmicos de processos.

Conforme Ljung (1999), a identificação de sistemas trata do problema da construção de modelos matemáticos de sistemas dinâmicos a partir de dados observados. Em qualquer das definições, entende-se como modelo de um sistema a relação entre os sinais observados. Todavia, um modelo matemático do sistema, por mais elaborado ou por maior precisão que tenha, invariavelmente será uma representação imperfeita do sistema real e a aplicação a que se destina determinado modelo é que definirá o seu grau de sofisticação, por esta razão justifica-se a inclusão do máximo de informações do processo (GARCIA, 2005).

Os modelos matemáticos têm se tornando cada vez mais importantes para a formulação do controle avançado ou controle preditivo multivariável. Eles são considerados indispensável nos meios científico e industrial para o entendimento e prospecção de soluções de problemas de processos industriais. Por sua vez, questões como a importância da incorporação de modelos de perturbações não medidas na estrutura do controle avançado, têm suscitado o interesse no meio acadêmico e industrial, com relação à sua efetividade na melhoria do controle.

1.2 REVISÃO BIBLIOGRÁFICA

Nesta seção é apresentada a revisão bibliográfica referente ao controle preditivo. Faz parte desta seção a exposição dos conceitos, funcionalidades, terminologias e estrutura do controlador preditivo baseado em modelo. Nas subseções subsequentes são apresentados trabalhos publicados relacionados com a performance de controle preditivo multivariável linear com a inclusão em sua estrutura do modelo de perturbações não medidas.

1.2.1 CONTROLE PREDITIVO

A teoria de controle preditivo baseada em modelos iniciou-se no final da década de 1970. Desde então, houve um grande desenvolvimento de novas abordagens e formulações para a resolução de problemas de sistemas multivariáveis. No final da década de 1970, apesar dos grandes avanços na teoria de controle, o segmento industrial, em particular a indústria química, permanecia usando o controle clássico (SEBORG *et al.*, 2011). Nessa época, o controle clássico era usado com maior frequência em virtude de não ser tão dependente de modelos para desenvolver a solução do problema de controle (THOMA; WYNER, 1991). No entanto, com o agravamento da crise mundial da indústria do petróleo, foi preciso buscar novas opções para controlar os processos. Neste caso, o controle clássico (PID) não era satisfatório para lidar com sistemas multivariáveis (CANG, 2010). Além dos fatores relacionados com o mercado mundial de petróleo, o aperfeiçoamento acelerado das tecnologias computacionais e digitais, contribuiu para a implementação das soluções de otimização e controle de processos, através do controle avançado (DECHECHI, 1998).

O conceito de horizonte deslizante foi publicado pela primeira vez no trabalho teórico de Propoi (PROPOI, 1963). Muito embora a ideia do controle preditivo tenha surgido na década de 1960, o interesse pela aplicação deste novo conceito ressurgiu no final da década de 1970, quando Richalet *et al.*, (1978) propuseram a técnica do primeiro controlador preditivo chamado MPHC (*Model Predictive Heuristic Control*), cuja aplicação era voltada para indústrias petroquímicas. Em seguida, a Shell Oil propôs a estratégia DMC (*Dynamic Matrix Control*), criada pelos pesquisadores Cutler *et al.*, (1983) (PRETT; RAMAKER; CUTLER, 1979). Posteriormente, Cutler *et al.* (1983) criaram uma versão do DMC denominada de QDMC (*Quadratic Dynamic Matrix Control*). O controle QDMC foi aprimorado por Garcia e Morshedi (GARCIA; MORSHEDI, 1986).

No trabalho publicado por Clarke *et al.* (1987) foi apresentado o controlador preditivo generalizado GPC (*Generalized Predictive Control*), disseminado no meio científico como controlador preditivo baseado em modelo MBPC (*Model Based Predictive Control*), (SEBORG *et al.*, 2011). Todos os algoritmos mencionados são aparentemente diferentes, mas compartilham da mesma estrutura, que inclui: modelo da planta, horizonte deslizante e o procedimento de otimização para obter a ação de controle, otimizando a evolução preditiva do sistema (GARCIA; PRETT; MORARI, 1989).

García *et al.* (1989), Richalet (1993), Muske e Rawlings (1993) apresentaram as vantagens do MPC (*Model Predictive Control*) quando comparado com controladores PID. Nestes artigos se destaca que processos ou sistemas com grandes tempos mortos, ou sistemas de fase não-mínima apresentam melhor performance quando se emprega o controle preditivo.

Muske e Rawlings (1993) propuseram uma modificação para o controlador preditivo, de modo a torná-lo estável para um horizonte de predição infinito. A hipótese de Rawlings e Moske (1993) sobre a estabilidade foi provada para o caso nominal, ou seja, quando o modelo real da planta coincide com o modelo considerado pelo controlador preditivo MPC.

No artigo escrito por Mayne e Michalska (1993), foi desenvolvido um MPC dual de horizonte finito, onde as ações de controle foram implementadas, a partir de um problema de otimização, com as restrições relaxadas através de inequações ao invés do uso de equações, que tornavam o problema de difícil convergência.

Lee, Morari e Garcia (1994) descreveram uma formulação para o controlador MPC, em espaço de estados, utilizando o modelo de resposta ao degrau através de técnicas de estimação de estados. Neste artigo foi demonstrado que o controlador MPC pode ser generalizado para processos que apresentam comportamento integrador, com perturbações medidas e ruído branco (LEE; MORARI; GARCIA, 1994).

De acordo com as formulações e parametrizações explícitas do ganho ótimo no desenvolvimento e evolução dos controladores MPC, o modelo em espaço de estados pode ser aplicado à maioria dos algoritmos do MPC, isto é, podem ser generalizados por um modelo em espaço de estados (LEE; YU, 1994).

Kothare *et al.* (1996) propuseram uma nova formulação para o MPC robusto, com ganho de realimentação de estado, obtendo uma nova parametrização (sintonia) para o ganho do controlador que satisfaça múltiplas desigualdades de Lyapunov, uma para cada vértice do poli-topo que constitui a representação das incertezas no modelo. Deste modo, o controlador MPC através da realimentação

de estados pode ser aplicado a sistemas onde as representações de incertezas estejam inseridas neste poli-topo, convergindo para soluções menos conservadoras.

No artigo de Lee e Yu (1997) foi proposto um controlador robusto que minimiza a função objetivo aplicada na pior condição dos modelos disponíveis no controlador. A função objetivo do controlador MPC considerava todos os modelos possíveis que a planta podia apresentar, usando o algoritmo Min-Max. Uma das desvantagens deste controlador foi em relação ao esforço computacional e tempo requerido superior para o cálculo da função objetivo de cada modelo e, dentro deste conjunto viável, existem combinações de modelos que seriam muito pouco prováveis de serem o modelo ideal da planta ou sistema.

Scokaert e Mayne (1998) apresentaram uma otimização em malha fechada e a minimização pelo pior caso, assumindo que as incertezas estejam contidas em um poli-topo construído a partir dos valores máximos aceitáveis para os distúrbios. Nesta abordagem, foi usada uma estratégia de controle dual, isto é, os estados do sistema são forçados a entrar em uma região robusta, positivamente invariante, onde as restrições nos estados e nas entradas sejam satisfeitas, garantindo a estabilidade do sistema. Esta formulação do controlador preditivo busca solucionar o problema da minimização do erro para a pior condição, acrescentando a este problema de otimização uma restrição terminal (SCOKAERT; MAYNE, 1998).

No trabalho de Rodrigues e Odloak (2000), foi apresentada uma nova abordagem para a formulação de MPC robusto com realimentação de saída, acrescentando, como restrição no problema de controle, a condição de estabilidade imposta pela desigualdade de Lyapunov. Os estados do sistema são estimados a partir da inclusão de um filtro de Kalman. A solução para os problemas de controle é resolvida através de LMIs (*Linear Matrix Inequalities*), que é uma ferramenta matemática aplicada na busca de soluções para sistemas lineares.

Ralhan e Badgwell (2000) propuseram um controlador preditivo MPC robusto, limitado a aplicações em processos estáveis, baseado em espaço de estados e com a incerteza prevista em um dado conjunto de modelos possíveis para o processo. Nesta formulação, a estabilidade é atingida com a inclusão de restrições que garantam a contração da função objetivo de cada modelo. Todavia, o controlador otimiza as ações de controle apenas para o modelo com a maior probabilidade de ocorrência, chamado de modelo nominal.

Rodrigues e Odloak (2002) apresentaram a formulação do controlador MPC com modelo OPOM (*Output Prediction Oriented Model*), isto é, modelo orientado a predição de saída. Este conceito de estado é de ordem mínima, requerendo um observador para estimar os estados a partir

das leituras obtidas do processo. Rodrigues e Odloak (2002) comprovaram que o IHMPC (*Infinite Horizon Model Predictive Control*), com formulação baseada no OPOM, tem estabilidade nominal garantida para processos estáveis. Este trabalho foi implementado a partir da estratégia originalmente proposta por Gouvêa e Odloak (1997) sob a designação de ROSSMPC (“*Reduced Order State-Space MPC*”).

Bemporad *et al.* (2002) propuseram uma estratégia para a síntese de um MPC com estabilidade nominal e sujeito a restrições nas entradas, onde o controlador é sintetizado *off-line*. Neste trabalho foi explicitado o problema de otimização para implementar o MPC. Bemporad *et al.* (2002) propuseram um algoritmo para resolver este problema. A estratégia apresentada contém limitações, isto é, a hipótese de que todos os estados tenham sua medição disponível e é restrita ao caso nominal, onde o processo corresponde ao modelo assumido no controlador.

No trabalho de Porfírio (2001) é descrita a aplicação de um controlador preditivo multi-modelo (*MMPC - Multi-Model Predictive Control*), para uma planta de destilação industrial (separadora C3/C4). Trata-se de um processo não linear e pode operar em diferentes condições operacionais. Neste controlador preditivo MPC estão inclusos seis modelos lineares obtidos em diferentes pontos operacionais do sistema, ou seja, modelado em espaço de estados. Segundo os resultados apresentados no trabalho, o MMPC apresentou um desempenho melhor em relação ao controlador convencional (PORFÍRIO; NETO; ODLOAK, 2003).

Um método de identificação de subespaço multivariável é proposto por Pannochia *et al.* (2006). Neste artigo foram apresentados os resultados das técnicas de identificação multivariável por subespaços para um processo de destilação, simulado com um modelo dinâmico rigoroso. Este método de identificação de subespaços multivariável é proposto para superar as dificuldades associados a grandes constantes de tempo do processo e identificar um modelo de processo linear, baseado no qual um controlador preditivo restrito é desenvolvido.

Além dos trabalhos citados anteriormente, há vários outros, os quais por restrições de espaço não foram destacados, optando-se por incluir as principais contribuições nesta área, de acordo com uma sequência cronológica histórica. É sabido que muitos estudos correlatos poderiam ser usados, porém, estes podem ser aproveitados em outros projetos/experimentos.

Desde a criação do controle preditivo, tem havido um grande interesse por parte da comunidade científica e da iniciativa privada, pelo aprimoramento do controle preditivo multivariável, justificado pelos benefícios relacionados com a performance na melhoria do controle regulatório de processos multivariáveis lineares e não lineares (MANSOUR, 2012).

A implementação do Controlador Preditivo Multivariável propicia uma maior estabilidade das variáveis controladas, além de tornar possível a otimização do processo, possibilitando aproximar-se da faixa de operação da planta, das restrições dos equipamentos e das especificações do produto. A implantação do controle preditivo multivariável baseado em modelo (*Model Predictive Control*) é uma solução adequada e robusta, quando se deseja garantir a adaptação do controle do processo para novos parâmetros de produção, restrições operacionais e função objetivo (CAMACHO; BORDONS, 2007). A utilização da tecnologia de controle MPC (Model Predictive Control) é adequada para processos com tempo-morto, interagentes, não linear, ou melhor, apropriada para plantas e sistemas multivariáveis com controle por restrições (*override*), sucedendo como uma alternativa para resolução de problemas regulatórios complexos (BEMPORAD *et al.*, 2002), (BECCUTI; GEYER; MORARI, 2004).

O crescente interesse pelo controle avançado na indústria petroquímica se deve ao êxito da otimização da função custo, sem a penalização da estabilidade e violação das restrições impostas por fatores econômicos e operacionais (HINOJOSA; CAPRON; ODLOAK, 2016).

De forma simplificada, as diversas formulações do controle preditivo estão apresentadas no diagrama da **Erro! Fonte de referência não encontrada..** A cada intervalo de amostragem, o algoritmo do controlador MPC responde as seguintes questões:

1. Atualização: qual a condição do processo (variáveis controladas)?
2. Alvo: para onde o processo deve ir (referência)?
3. Controle: como atingir o objetivo (variáveis manipuladas)?

Figura 1: Diagrama de blocos do algoritmo MPC.

Fonte: Adaptado de (BADGWELL, 2010).

1.2.2 CONTROLE PREDITIVO MULTIVARIÁVEL BASEADO EM MODELO

O termo Controle Preditivo baseado em Modelo (*Model-Based Predictive Control*) ou apenas controle preditivo é usado para descrever uma classe de técnicas de controle, em que o modelo dinâmico do processo é incorporado na estrutura do controlador (MOUDGALYA, 2007). Inicialmente, o controle preditivo tornou-se uma solução usual nas indústrias petroquímicas e sistemas de potência. Com o aumento da capacidade computacional, a sua aplicação foi disseminada para outras áreas, como as indústrias alimentícias, metalúrgicas, papelarias, sistemas biológicos e medicina (ZHENG, 2010). O controle preditivo não é uma única estratégia, mas sim um conjunto, nas quais as ações de controle visam otimizar, em tempo real, o comportamento futuro do processo, visando minimizar uma função custo que representa um compromisso entre o erro na saída comparada a um referencial e à energia gasta para a redução deste erro (XI; LI; LIN, 2014).

Este comportamento é predito utilizando um modelo matemático representativo do processo. À medida que novas observações da saída são feitas, as futuras ações de controle são atualizadas, ou seja, faz-se uso da realimentação. A cada novo período de amostragem, a otimização do comportamento do processo é recalculada. Esta estratégia é conhecida como horizonte retrocedente (CAMACHO; BORDONS, 2004). A metodologia de todos os controladores pertencentes à família MPC é caracterizada pela estratégia ilustrada na Figura 2.

Figura 2. – Esquema ilustrativo das estratégias do controle preditivo.

Fonte: Adaptado de (NORMEY-RICO; CAMACHO, 2007).

De acordo com a **Erro! Fonte de referência não encontrada.**, com base nos valores do *set-point* (alvo) do controlador preditivo, em um determinado instante de amostragem k , recebe informações sobre o estado do sistema e, baseado nestas informações e no modelo do processo, prediz o comportamento futuro do sistema $\hat{y}$, em todo o horizonte de predição (p). A partir daí, determina-se a trajetória das variáveis manipuladas, para todo o horizonte de controle (c) tal que $c \leq p$.

Estas variáveis otimizam uma função objetivo predeterminada. Como hipótese, se o modelo identificado representa fielmente o processo real, se não houve perturbações e se o problema de otimização puder ser resolvido para um horizonte infinito, toda a trajetória das variáveis manipuladas (u) calculada no instante k , poderia ser implementada (NORMEY-RICO; CAMACHO, 2007). A Figura 3 mostra através do diagrama de blocos a estrutura básica do controlador preditivo MPC. Esta estrutura básica reúne os seguintes blocos: modelo matemático do processo, otimizador (algoritmo de predição e cálculo das ações de controle e cálculo das referências) e variáveis medidas (BRAVO; NORMEY-RICO, 2009).

Figura 3 – Estrutura básica do controlador preditivo MPC.

Fonte: Autor.

Na **Erro! Fonte de referência não encontrada.** observa-se que as variáveis $u(k)$, $y(k)$ e $r(k)$ representam os valores do sinal de controle, da variável controlada e do sinal de referência, respectivamente. Os valores futuros dessas variáveis podem ser representados pelos vetores das Equações de (1) a (4).

$$r(k + i) \text{ é a trajetória de referência} \quad (1)$$

$\hat{y}(k + i)$ é a saída predita i passos à frente com as leituras/sensores obtidas em k (2)

$u(k + i - 1/k)$ é a ação de controle predita $i-1$ passos à frente em k (3)

$u(k/k)$ é a ação de controle ótima (4)

Em síntese, o algoritmo do controlador MPC calcula das saídas de controle visando manter ou levar as variáveis controladas para os respectivos *set-point* através de um problema de otimização matemática (RICHALET; O'DONOVAN, 2009). A otimização é executada a cada instante de amostragem k , determinado as saídas de controle futuras, de maneira a minimizar a função objetivo, de acordo com a Equação (5).

$$J = \sum_{i=k}^{k+p} Y_i (\hat{y}_i(k) - y_{set_i}(k))^2 + \sum_{j=k}^{k+c} \lambda_j \Delta u_j^2(k) \quad (5)$$

onde:

$\hat{y}_i$ é a saída predita pelo modelo no instante i

y_{set_i} é o valor dos *set-point* ou trajetória a ser seguida no instante i

Y_i é o peso do erro na variável controlada no instante i

λ_k é o fator de supressão de movimento da saída de controle no instante k

Δu_k é o valor da saída de controle no instante k

p é o horizonte de predição

c é o horizonte de controle

O problema de otimização é resolvido a cada intervalo de amostragem, porém, não deve ultrapassar os limites das restrições de processo. As restrições relacionadas com as saídas de controle devem ser consideradas durante toda a excursão do horizonte de controle (c) e as restrições da saída da planta devem ser respeitadas ao longo de todo o horizonte de predição, desde o instante k até $k+p$, de acordo com as equações de desigualdades (6) a (8):

$$u_{min} = \left\lfloor \frac{k+c}{k} \right\rfloor \leq u = \left\lceil \frac{k+c}{k} \right\rceil \leq u_{max} = \left\lceil \frac{k+c}{k} \right\rceil \quad (6)$$

$$\Delta u_{min} = \left\lfloor \frac{k+c}{k} \right\rfloor \leq \Delta u = \left\lceil \frac{k+c}{k} \right\rceil \leq \Delta u_{max} = \left\lceil \frac{k+c}{k} \right\rceil \quad (7)$$

$$y_{min} = \left\lfloor \frac{k+p}{k} \right\rfloor \leq y = \left\lceil \frac{k+p}{k} \right\rceil \leq y_{max} = \left\lceil \frac{k+p}{k} \right\rceil \quad (8)$$

As definições relativas às quatro operações do controlador MPC são indicadas a seguir:

- ✓ Especificação da trajetória de referência (y_{set}): define a trajetória que a variável controlada deve seguir. Pode ser um simples degrau nos *set-point* ou uma função mais suave do tempo, como uma rampa ou a resposta a degrau de um filtro de primeira ordem;

-
- ✓ Predição da variável controlada ($\hat{y}$): considerando um modelo discreto da planta, onde k é o instante de tempo atual, consiste em prever os valores de $\hat{y}(k+2), \dots, \hat{y}(k+i)$ para i instantes de tempo no futuro, baseado em j saídas de controle passadas dadas por $u(k-1), u(k-2), \dots, u(k-j)$ e pelas saídas de controle calculadas em $y(k)$;
 - ✓ Sequência de ações de controle (Δu): a partir do modelo discreto da planta, é feito o cálculo da sequência de ações de controle $\Delta u(k), \Delta u(k+1), \dots, \Delta u(k+c-1)$, que minimizam a função objetivo J , de acordo com a Equação (5). A utilização da função objetivo visa minimizar o erro entre a saída predita do processo e os *set-point* em p instantes de tempo no futuro, otimizando o esforço de controle aplicado, além de não violar as restrições, caso estejam parametrizadas na formulação;
 - ✓ Atualização do erro de predição (W): uma vez detectada diferenças entre o modelo da estrutura interna do controlador e o modelo da planta, somada à presença de distúrbios que podem afetar a saída do processo, o algoritmo calcula o erro de predição, segundo adequação $W(k) = y(k) - \hat{y}(k|k-1)$. Este erro é usado para atualizar previsões futuras e é assumido constante ao longo da predição, na maioria das formulações do MPC.

O algoritmo do MPC é capaz de solucionar problemas relacionados com acoplamentos entre as variáveis controladas, com intensas interações ou acoplamentos entre si, e tornar a operação da planta nos limites de máximo rendimento ou condições de projeto e diminuir sensivelmente a variabilidade do processo (ZHENG, 2010).

O controle preditivo é dividido em duas áreas de pesquisa e desenvolvimento que são: o controle de sistemas lineares e não lineares. O controle preditivo linear pode ser aplicado para soluções de problemas de controle regulatório, desde que o sistema atue nas vizinhanças de uma faixa operacional, onde o comportamento dinâmico do processo possa ser aproximado satisfatoriamente por um modelo linear com atraso (MAGNI *et al.*, 2009).

Apesar de haver muitos trabalhos publicados na área de controle preditivo linear, ainda há temas em aberto, que precisam ser pesquisados, como por exemplo: estudos sobre a estabilidade na presença de perturbações não medidas; estudos sobre a garantia de estabilidade na presença de incertezas e restrições nos sinais de controle e de saída, em sistemas de controle com atraso dominante; estudo sobre aplicações em sistemas com dinâmica integradora ou instável.

1.2.3 CONTROLE PREDITIVO MPC COM MODELO EM ESPAÇO DE ESTADOS

Devido à habilidade de incorporar restrições nas entradas e saídas, os controladores preditivos têm sido aplicados nos ambientes industrial e acadêmico. Este aspecto é importante para o sucesso de uma aplicação de controle de processos, uma vez que estes sistemas, na prática, têm limites físicos nas suas variáveis, impostos por restrições nas variáveis manipuladas ou controladas. A grande maioria dos controladores preditivos aplicados em processos industriais usa modelos de resposta ao degrau ou de resposta ao impulso finito (FIR - *Finite Impulse Response*) para realizar a predição dos valores das saídas. Já do ponto de vista acadêmico, a maioria dos artigos relacionados ao MPC adota a representação dos modelos em espaço de estados. Esta representação é bastante conveniente para estudar sistemas de controle, uma vez que as ferramentas matemáticas existentes para análise e síntese de sistemas em malha fechada são normalmente baseadas neste tipo de representação.

Em Lee; Morari e Garcia (1994) é mostrada uma interpretação em espaço de estados para o MPC baseada em modelo de resposta ao degrau.

Pode-se usar um modelo em espaço de estados resultante da linearização de um modelo fenomenológico ou um modelo correspondente à função de transferência discreta. Neste estudo, considerou-se que o modelo utilizado pelo MPC é descrito pelas Equações (9) e (10):

$$\mathbf{x}(k+1) = \mathbf{A} \mathbf{x}(k) + \mathbf{B} \Delta \mathbf{u}(k) \quad (9)$$

$$\mathbf{y}(k) = \mathbf{C} \mathbf{x}(k) \quad (10)$$

onde:

$\mathbf{x} \in \mathbb{C}^{nx}$ é o vetor de estados

$\mathbf{u} \in \mathbb{R}^{mu}$ é o vetor de entradas

$\mathbf{y} \in \mathbb{R}^{ny}$ é o vetor de saídas

$\Delta \mathbf{u}(\mathbf{k}) = \mathbf{u}(\mathbf{k}) - \mathbf{u}(\mathbf{k}-1)$

$\mathbf{k}$ é o instante de tempo atual

$\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$ são matrizes com as dimensões apropriadas.

nx representa o número de estados, nu número de estradas e ny é o número das saídas da planta ou sistema.

1.2.4 CONTROLE PREDITIVO COM MODELO DE PERTURBAÇÕES NÃO MEDIDAS

Santoro (2015) apresentou o desenvolvimento do controle preditivo estocástico SMPC (*Stochastic Model Predictive Control*), com inclusão de especificações relativas à inclusão de ação integral no controlador através da descrição do modelo, inclusão das restrições (*hard*) nas estradas e restrições probabilísticas nos estados. Outro aspecto do trabalho é o controle por zonas de sistemas sujeitos a distúrbios, um tipo de problema comum na indústria. Santoro (2015) afirma que todos os algoritmos de controle preditivo apresentados no trabalho, baseiam-se na suposição das medições do ruído do processo, porém não foi possível simular o comportamento do controlador frente a perturbações não medidas, por ser tratar da simulação de um processo com comportamento estocástico. Como contribuições futuras, Santoro (2015) sugere a investigação sobre a efetividade do emprego do modelo das perturbações não medidas, que em determinadas condições poderá alterar a faixa de operação do controlador.

No trabalho de Capron *et al.* (2016), apresenta-se a análise de desempenho do controlador preditivo IHMPC (*Infinite Horizon Model Predictive Control*), baseado em espaço de estados realinhado, que não requer um observador ou estimador, com características de rejeição a perturbações não medidas, adequado para aplicações industriais fortemente perturbadas. Neste artigo, Capron *et al.* (2016) concluem que o controlador preditivo IHMPC com modelo realinhado, com o uso de dados simulados, obteve melhor eficiência em relação ao controlador IHMPC convencional, quando submetidos a cenários fortemente perturbados. Embora os resultados tenham sido satisfatórios, o emprego de dados não reais pode apresentar lacunas quando comparados com ambientes reais, sendo que esse aspecto é focado neste trabalho, através do uso de dados identificados de uma planta real e da aplicação do controle preditivo a essa planta real.

O artigo de Clarke *et al.* (1987) apresenta os resultados da simulação do controlador preditivo GPC (*Generalized Predictive Control*) com modelo de perturbações não medidas. O objetivo desta abordagem foi investigar a performance do controlador preditivo frente às perturbações não medidas. Os resultados deste artigo mostram um desempenho satisfatório com relação à rejeição de perturbações não medidas. Todavia, neste trabalho não é feita a comparação entre controladores com e sem modelo de perturbação não medida. Outro aspecto não explorado nesse artigo foi o uso de modelo da dinâmica de um processo real (planta), isto é, os dados utilizados para elaboração do modelo e simulação do controlador GPC não representaram algumas especificidades típicas da dinâmica de um processo real, principalmente os efeitos de perturbações não medidas.

Cabe destacar que o fato do trabalho de Clarke *et al.* (1987) não realizar a análise comparativa entre controladores MPC com e sem modelo de perturbação não medida, torna inédito e oportuno o escopo desta tese (comparação de desempenho do controlador MPC com e sem modelo de perturbação não medida, usando o modelo de uma planta real). Embora a grande maioria das aplicações industriais tipicamente apresente problemas relacionados com as restrições e distúrbios não medidos, considera-se pouco expressiva a quantidade de artigos publicados, que trata desse tema, isto é, a problemática do controle preditivo sob restrições e perturbações não medidas, especialmente voltada para aplicações práticas (CAMACHO; BORDONS, 2007).

Segundo Ljung (1999), é importante reunir o máximo de informações da dinâmica do processo. É possível observar o comportamento real da planta e formular comparações sobre certos aspectos do sistema físico com a sua descrição matemática, mas é impraticável estabelecer qualquer conexão ou correlação exata sobre causa e efeito. Dentre estas observações destacadas por Ljung (1999), possíveis de serem formuladas, estão as perturbações não medidas. De acordo com Camacho e Bordons (2007), o ruído branco é um sinal aleatório com igual intensidade em diferentes frequências, não auto-correlacionadas, com média zero e variância finita. Por sua vez, os componentes do ruído colorido podem ser combinados em uma sequência aleatória, cuja resultante tem média diferente de zero, em um tempo finito.

O modelo identificado deve ter maior precisão, de modo a se aproximar do comportamento real do processo, em uma ampla faixa operacional e com maior precisão, que permita ao Controlador Preditivo Multivariável operar, sem transpor ou violar as restrições do processo e a função custo. Segundo Keyser e Ionescu (2004), a incorporação do modelo de perturbações não medidas no algoritmo do controlador preditivo MPC, contribui para a melhoria do desempenho do sistema, isto é, trata-se de uma informação útil que pode propiciar a eliminação do erro em estado estacionário. Segundo Capron (2014), plantas industriais são suscetíveis a perturbações não medidas, não sendo apropriado afirmar que toda planta está isento do efeito de perturbações não medidas.

Há unidades de processamento de petróleo e gás, tais como: reatores de xisto, fornos de reforma e petroquímicos e tratamento de gás ácido, que são afetadas por perturbações não medidas. Nesses tipos de processos há uma dificuldade em implementar uma identificação isenta de ruído colorido ou “limpa”, sendo necessário inserir o modelo de perturbações não medidas na formulação do controlador MPC.

Para a incorporação do modelo de perturbações não medidas, é preciso que o algoritmo do controlador preditivo permita a inclusão desta informação (PANNOCCHIA; RAWLINGS, 2001). Todavia, observa-se que nas unidades de refino da PETROBRAS, o controle preditivo multivariável

não utiliza em sua estrutura interna o modelo de perturbação não medida. Nos processos industriais, de forma geral, o controlador preditivo multivariável DMC (*Dynamics Matrix Control*) é utilizado com maior frequência, entretanto esse controlador não permite a incorporação do modelo de perturbações não medidas. No entanto, é possível implementar algoritmos para controladores preditivos multivariáveis que permitam a incorporação do modelo de perturbações não medidas, quando necessário (LJUNG, 1999).

No artigo de Pannochia e Rawlings (2001) é apresentada a simulação do controlador preditivo robusto para sistemas multivariáveis com modelo de distúrbio. Porém, trata-se de uma abordagem da otimização da função custo na presença de distúrbios medidos. Segundo Pannochia e Rawlings (2001), o assunto perturbações medidas e não medidas merece ser explorado, isto é, a inexistência do modelo de perturbações não medidas pode afetar a robustez do controlador e degradar a função de otimização.

1.3 MOTIVAÇÃO

Desde o surgimento do controle preditivo MPC (*Model Predictive Control*) no final dos anos 1970 até hoje, é uma das técnicas de controle avançado mais usadas em aplicações industriais, principalmente na área de refino do petróleo e na indústria petroquímica. O controle preditivo é adequado para aplicação em processos com características dinâmicas complexas, multivariáveis, com restrições nas variáveis controladas e manipuladas, tempo morto elevado, não linearidades e perturbações não medidas. Alguns dos benefícios do uso do controle preditivo em unidades produtivas são (ZAKHAROV; BOSMAN; JA, 2013):

1. Capacidade de reduzir a variabilidade de variáveis críticas;
2. Controle de restrições ambientais e de projeto;
3. Otimização da rentabilidade econômica;
4. Aumento da capacidade produtiva, com a redução do reprocessamento de produtos em razão de problemas de especificação;
5. Diminuição de efluentes e consumo de energia;
6. Previsibilidade de ações de controle; e
7. Compensação antecipatória de perturbações medidas.

No entanto, para formular o controle preditivo é preciso conhecer o modelo matemático que descreve o comportamento dinâmico do processo, diferentemente do controle clássico, que não usa

um modelo explícito da planta no projeto do controlador (LJUNG, 1999). O modelo matemático do processo pode ser obtido através da aplicação de relações físico-químicas (modelagem fenomenológica) ou através da utilização de dados empíricos (identificação de sistemas) (LEBLANC; COUGHANOWR, 2009). Em identificação de sistemas, o modelo matemático é obtido através da realização de experimentos, utilizando métodos que têm como propósito explicitar as características do processo, em torno de sua condição nominal de operação. Um dos principais objetivos da modelagem matemática é disponibilizar modelos com capacidade de predição, de tal modo que o modelo represente com precisão o comportamento dinâmico do sistema (LJUNG, 1999).

Nos últimos anos, tem-se observado um crescente interesse no emprego de estratégias baseadas em modelos, tanto no meio acadêmico quanto no meio industrial, para o desenvolvimento de controle avançado e otimização de processos, visando aumentar a competitividade e a rentabilidade da atividade econômica (XU; HUANG; AKANDE, 2007). Neste contexto, é necessário identificar modelos com maior precisão, de modo a se obter a melhor aproximação possível do comportamento dinâmico do sistema real (SÖDERSTRÖM; STOICA, 2001).

À medida que um processo ou sistema se torna mais complexo, haverá uma maior necessidade de técnicas de modelagem matemática que propiciem a incorporação de informações correlacionadas com a dinâmica do sistema em resposta a estímulos de entrada, isto é, o modelo matemático deverá ser compatível e ajustado para resolver um problema particular associado ao sistema ou planta, onde o grau de detalhe requerido depende do problema a ser resolvido e da quantidade de dados disponíveis. Quanto mais rigorosa for a descrição de um processo ou planta, o conjunto de modelos matemáticos resultantes será maior (SECCHI, 1995).

De acordo com Ljung (1999), através da Identificação de Sistemas é possível estabelecer uma conexão de causa e efeito entre as variáveis físicas do processo. O modelo matemático da dinâmica do processo deve explicitar as relações entre as variáveis controladas, manipuladas e perturbações não medidas. As perturbações não medidas são consideradas na literatura como ruído colorido (*coloured noise*). O ruído colorido é uma perturbação estocástica, com correlação diferente de zero, isto é, a variância média é diferente de zero em um tempo finito. De acordo com algumas correntes de pensamento científico, o modelo de perturbações não medidas deve ser incorporado na estrutura do controlador preditivo ou avançado, pois representa um diferencial no desempenho e robustez da aplicação (ANSARPANAHI; NOOR; MARHABAN, 2008).

As perturbações não medidas ou ruído colorido estão presentes em uma grande parte dos processos químicos, o que torna recomendável considerá-las no desenvolvimento de controle preditivo multivariável (PATIL; SHARMA, 2014). A precisão do modelo da planta pode ser

comprometida se o efeito de distúrbios não medidos não estiver contido em um conjunto de dados utilizados para identificar a dinâmica do processo (ZHU, 2001). As principais fontes de perturbações não medidas são decorrentes do ruído de medição (sensores de campo) ou ruído de processo. O ruído de medição é conhecido como ruído branco. Este tipo de sinal é classificado como estocástico ou randômico e não pode ser expresso por uma função matemática. O ruído branco ou ruído aditivo gaussiano é um sinal aleatório (estacionário) de média nula com igual intensidade em diferentes frequências, o que lhe dá uma densidade espectral de potência constante.

No entanto, as fontes de perturbações não medidas oriundas das variações da composição da carga de um sistema ou unidade, no caso deste trabalho, teor de umidade na rocha de xisto, tem características diferentes dos sinais de ruído de sensores. As perturbações não medidas de processo não podem ser representadas através de uma curva característica. Estas curvas são do tipo senoidal, rampa ou gaussiana e estão associadas com uma variância¹, potência e frequência do sinal de perturbação não medida (BEMPORAD *et al.*, 2019).

Outro modo de caracterizar os sinais de perturbações não medidas é classificá-los em sinais de energia e sinais de potência. Os sinais de energia são os que possuem potência média igual a zero como, por exemplo, os sinais transitórios (ruído de sensores). Todavia, os sinais de perturbação não medidas de processo, possuem potência média finita, isto é, ocorrem com uma determinada periodicidade como, por exemplo, a variação da viscosidade ou poder calorífico de um gás, variação do teor óleo ou carbono na carga de petróleo, teor de umidade na carga de xisto, etc. Todas estas são consideradas perturbações não medidas e podem ocorrer com uma determinada periodicidade. Os métodos ou experimentos para a caracterização destas diferentes fontes de perturbações não medidas são realizados através da utilização de filtro em sinais do ruído branco com a variância característica dos sinais amostrados, ou seja, de acordo com os dados coletados durante a identificação do modelo matemático da planta (BEMPORAD *et al.*, 2019).

No entanto, a obtenção de modelos representativos da dinâmica do processo exige um volume de informações que propicie entender as relações constitutivas das reações químicas, algo que na maioria das vezes torna impraticável a construção de algoritmos de controle aderentes ao processo real (ROFFEL; BETLEM, 2006). A modelagem matemática propicia representar as relações de causa e efeito, entre um conjunto finito de variáveis de processo, por meio de equações e parâmetros. Uma vez obtido o modelo matemático que representa o comportamento estático e

¹ A variância é definida como o desvio quadrático médio da média, isto é, é o quadrado do desvio-padrão. A variância é uma das ferramentas que mostra a dispersão de uma amostra, série ou população com relação à média destas. Para obtenção da variância é necessário calcular a média dos desvios quadrados de uma série em relação à média da série (AZEVEDO, 2016) (MORETTIN, 1999), (MANUELA; FERNANDES, 1999).

dinâmico do sistema, por meio de técnicas de identificação, pode-se então desenvolver algoritmos de controle preditivo ou avançado, aderentes às características da planta (LJUNG, 1999).

Como nenhum modelo matemático representa perfeitamente um sistema físico, procura-se através de métodos de identificação de sistemas, representar, relacionar e quantificar as variáveis controladas e manipuladas, perturbações medidas e não medidas, de modo a reduzir as incertezas do modelo (FELÍCIO, 2010). As incertezas devem ser consideradas no projeto do controle preditivo multivariável, pois podem comprometer significativamente o desempenho do controlador em relação às variações de carga e ponto de operação (RICHALET; O'DONOVAN, 2009). O modelo matemático representa a dinâmica² da planta em torno de um ponto nominal de operação, isto é, em uma condição operacional que permita identificar as interações entre variáveis controladas, manipuladas e perturbações não medidas (BERNSTEIN, 1987).

Nas últimas décadas surgiram outras questões relacionadas com a melhoria dos indicadores de desempenho dos processos industriais, tais como: margem de estabilidade, atenuação de perturbações, entre outros. Neste novo cenário, os indicadores de desempenho das unidades produtivas passaram a ter um destaque maior na avaliação quantitativa e qualitativa da performance da planta (CAMPOS; TEIXEIRA, 2006).

O fato de não se considerar perturbações não medidas pode, em alguns casos, comprometer a performance do sistema de controle (CAMACHO; BORDONS, 2007). O desempenho do controlador preditivo depende de alguns fatores, dentre estes destaca-se com grande relevância o modelo matemático da planta. Um modelo impreciso pode resultar em uma formulação equivocada do comportamento dinâmico da planta (DOYLE; GUNTER, 1991). As hipóteses relativas ao desempenho do controlador preditivo projetado com base em um modelo que inclua as perturbações não medidas suscitam uma análise investigativa, pois pode trazer contribuições para os projetos de controladores preditivos mais eficientes.

Como citado por pesquisadores da área de identificação de sistemas e controle de processos, a performance do controlador preditivo pode ser deteriorada, caso submetido a perturbações não medidas, cujo modelo não seja considerado no controlador (CLARKE; MOHTADI, 1987). Cabe ainda destacar que, durante a fase da pesquisa bibliográfica, constatou-se que há um número pequeno de artigos publicados abordando o assunto, porém sem efetivamente comparar o desempenho dos controladores com e sem modelo de perturbações não medidas.

² Um sistema é dito dinâmico ou o comportamento dinâmico de um processo é quando sua saída $y(t)$ não depende exclusivamente da entrada $u(t)$ naquele instante, mas da evolução histórica da entrada e da saída. Sistemas cujas saídas dependem exclusivamente da entrada naquele instante são denominados sistemas estáticos (LJUNG, 1999).

A principal contribuição deste trabalho é comparar o desempenho do controlador preditivo MPC com modelo de um processo real, submetido a perturbações não medidas, tornando oportuna a exploração experimental e análise da performance do controlador preditivo MPC atuando sobre uma planta simulada, com potencial de aplicação futura em uma planta real, quando se considera ou não em sua estrutura o modelo das perturbações não medidas. A hipótese que se pretende responder nesta tese é: o controlador preditivo MPC com modelo de perturbação não medidas é adequado para rejeitar as perturbações estocásticas, reduzindo o erro em regime estacionário, propiciando uma melhoria na controlabilidade do processo através da redução da variabilidade quando submetido a perturbações não medidas.

1.4 OBJETIVOS

O objetivo principal desta tese é a comparação do desempenho do controlador preditivo com e sem modelo de perturbação não medida. Para alcançar este objetivo foram planejadas as seguintes etapas:

- a) Estudar os controladores preditivos MPC, implementados com modelo de perturbações não medidas (H), usando a ferramenta MATLAB™;
 - b) Planejar e realizar a pré-identificação do forno industrial de 50MW, utilizando sinal de excitação tipo degrau;
 - c) Planejar e executar a identificação do modelo matemático do forno industrial, usando sinais de excitação binários aleatórios *PRBS*;
 - d) Desenvolver o controlador MPC convencional (MATLAB™), com a presença e ausência do modelo de perturbações não medidas, denominado M_{MPC} (*Model Predictive Control with Non-Measured Disturbance Model*), usando a ferramenta MATLAB™;
 - e) Sintonizar o controlador MPC usando o algoritmo genético MOGA (*Multi-Objective Genetic Algorithm*), contribuindo para a difícil tarefa de sintonia de controladores MPC;
 - f) Preparar ambiente computacional e simular os cenários com as respectivas parametrizações das condições nominais do processo industrial identificado, isto é, utilizando-se dados obtidos da identificação do processo real (forno industrial 50MW);
 - g) Realizar a análise comparativa entre os controladores preditivos MPC com e sem modelo de perturbações não medidas e verificar o desempenho de ambos, através da utilização do critério IAE (*Integral of Absolute Error*);
-

-
- h) Responder a hipótese formulada: o controle preditivo com o modelo de perturbação não medida é adequado para rejeição de perturbações estocásticas?

1.5 CONTRIBUIÇÕES

Uma das contribuições deste trabalho é a pesquisa experimental, gerada através da identificação do modelo matemático de uma planta industrial real e a aplicação desse modelo na estrutura de um controlador MPC, considerando ou não o uso do modelo de perturbações não medidas para cada uma das variáveis controladas. Pretende-se responder à questão de desempenho entre as duas formulações da estrutura dos controladores MPC, ou seja, efetua-se uma análise comparativa do comportamento dos controladores preditivos. Espera-se que o resultado deste trabalho possa contribuir para os meios acadêmico e industrial, mediante a resposta à hipótese formulada com relação ao desempenho dos controladores MPC. Outras contribuições podem ser destacadas com relação ao presente trabalho:

- a) A revisão bibliográfica que versa sobre o tema, permitindo explicitar as correntes de pensamentos entre os pesquisadores de controle preditivo multivariável; e
- b) Oportunidade para explorar a abordagem para sintonia dos parâmetros dos controladores preditivos multivariáveis, através da utilização do algoritmo genético multiobjectivo (MOGA- *Multi-Objective Genetic Algorithm*). Esta ferramenta visa otimizar, através do algoritmo genético, os parâmetros de sintonia de controladores preditivos (M_{MPC} - *Model Predictive Control with Non-Measured Disturbances*).

1.6 ESTRUTURA DO TRABALHO

O Capítulo 2 apresenta o forno industrial, responsável pela geração de energia térmica no processo PETROSIX®. Neste capítulo é realizada uma breve descrição das malhas de controle e características do forno industrial.

O Capítulo 3 apresenta o planejamento das atividades para o experimento de identificação do modelo matemático do forno industrial.

O Capítulo 4 descreve o processo de pré-identificação realizado na planta, usando sinais de teste do tipo degrau. Neste capítulo é descrita a metodologia para obter o modelo da planta.

O Capítulo 5 descreve a identificação da planta utilizando sinais de excitação do tipo sequências binárias pseudoaleatórias (*Pseudo-Random Binary Sequence, PRBS*).

O Capítulo 6 apresenta os ensaios, a formulação a sintonia do controlador preditivo MPC sem modelo e com modelo de perturbações não medidas. Para a sintonia do controlador utilizou-se a ferramenta computacional MOGA, ou seja, o método de sintonia utilizado para encontrar os melhores parâmetros do MPC.

No Capítulo 7 se realiza a comparação entre os controladores MPC com e sem modelo de perturbação não medida (H). No final deste capítulo são apresentadas as conclusões relativas à análise comparativa entre as duas implementações do controlador preditivo.

O Capítulo 8 apresenta as conclusões finais e oportunidades de continuidade desta pesquisa.

O Apêndice A disponibiliza a lista com os códigos da implementação dos controladores preditivos multivariáveis, estruturados com modelo de perturbações não medidas.

O Apêndice B faz uma breve abordagem sobre as principais características dos controladores preditivos multivariáveis disponíveis no mercado. Não faz parte do escopo deste trabalho efetuar a análise comparativa entre as soluções comerciais, mas sim avaliar características da estrutura interna e funcionalidades disponíveis para o desenvolvimento de controladores mais sofisticados.

O Apêndice C apresenta a planta industrial de processamento de Xisto Betuminoso, patenteada como processo PETROSIX®. É realizada uma breve descrição da planta industrial de processamento de xisto e é feita uma abordagem, de forma resumida, sobre os aspectos operacionais dos sistemas que envolvem este processo.

CAPÍTULO 2

PLANTA INDUSTRIAL – XISTO

Este capítulo apresenta uma descrição resumida do forno industrial de 50 MW, responsável pela geração de energia térmica para o processo de pirólise da planta PETROSIX®. Na indústria de óleo e gás, os fornos petroquímicos são as principais fontes de complementação térmica, energia necessária para o processamento de derivados de petróleo. Ainda neste capítulo abordam-se as funcionalidades principais das malhas de controle.

2.1 O FORNO INDUSTRIAL DE 50 MW

O forno industrial é considerado um equipamento crucial para o processo de extração dos componentes do minério de xisto, ou seja, o controle das temperaturas de topo, pirólise, leito e fundo, são primordiais para manter a estabilidade da produção e a especificação dos produtos.

O forno industrial é composto por câmaras de combustão e convecção com geometria retangular. A câmara de combustão é montada na posição vertical e a de convecção na horizontal. Na parte superior do forno estão instalados 12 queimadores, responsáveis por gerar energia térmica usando como combustível óleo e/ou gás combustível. A principal função do forno é manter a temperatura do gás de processo de reciclo quente (gás de retortagem) dentro de limites pré-estabelecidos. A temperatura de saída do gás de processo (retortagem) deve ser mantida constante, independente da vazão ou temperatura de entrada.

Na Figura 4 vê-se um diagrama esquemático do forno industrial, que é usado como interface operacional no SDCD do forno e na Figura 5 mostra-se uma foto dele.

Figura 4 – Diagrama esquemático usado no SDCD do forno industrial de 50 MW.

Fonte: Autor (P&D).

Figura 5– Foto do forno industrial de 50 MW.

Fonte: Autor (P&D).

Segundo Nunes (2013), as variações na concentração de carbono do xisto, variações do teor de óleo, espessura da rocha hospedeira e materiais inertes adicionados à carga, geram alterações nas características do gás de processo e, portanto, mudam o poder calorífico do óleo e gás combustível, além dos impactos na produção. Estas alterações, por sua vez, refletem diretamente no controle de temperatura do forno industrial. O efeito no controle da temperatura é causado principalmente pela variação do poder calorífico do gás combustível e óleo, usados para gerar energia térmica, para fornecer um incremento de temperatura no gás de processo.

Nunes (2013) afirma que estes efeitos foram identificados e assimilados a partir de dados históricos e reproduzem o comportamento do processo de retortagem quando há variações na pilha de xisto, o que ocorre com uma certa frequência, isto é, há uma variação na qualidade da carga. Além da influência das características da carga de xisto, o tempo de residência para o ciclo de pirólise pode alterar o volume de gás produzido. Por fim, Nunes (2013) sugere que se implante controle avançado nas malhas do forno, usando o controle preditivo, todavia é importante que sejam incluídas as perturbações não medidas no modelo identificado a ser usado no controle preditivo.

2.2 MALHAS DE CONTROLE DO FORNO INDUSTRIAL

No forno industrial há três variáveis controladas e três variáveis manipuladas, responsáveis pelo processo de geração de energia térmica, as quais são mostradas, respectivamente, nas Tabela 1, Tabela 2 e 3.

Tabela 1 - Variáveis controladas do processo de geração de energia térmica do forno industrial.

Variáveis controladas	Descrição
AIC-23001	Concentração de oxigênio (O_2) nos gases de combustão
PIC-23039	Pressão do tronco de gás combustível
TIC-23099	Temperatura do gás de processo – saída do forno para retorta

Fonte: Autor.

Tabela 2 - Variáveis manipuladas do processo de geração de energia térmica do Forno Industrial.

Variáveis Manipuladas	Descrição
FIC-23027	Vazão de óleo combustível
FIC-23028	Vazão de gás combustível
FIC-23025	Vazão de ar para combustão

Fonte: Autor.

Tabela 3 - Perturbação medida.

Perturbação medida	Descrição
FIC-23003	Vazão de gás processo

Fonte: Autor.

Na Figura 6 é mostrado o P&ID simplificado do forno industrial e na **Erro! Fonte de referência não encontrada.** o P&ID detalhado.

Na Tabela 1 são destacadas as variáveis controladas do forno industrial, na Tabela 2 as variáveis manipuladas e na Tabela 3 a perturbação medida. A TIC-23099 é uma das principais variáveis controladas do forno. Esta variável é responsável por manter a temperatura no reator (retorta) do processo PETROSIX®, na região conhecida como pirólise, em torno de 560°C a 570°C (limites operacionais de projeto). De acordo com o teor de óleo na carga de xisto, a temperatura necessária para a ocorrência das reações de pirólise pode variar dentro dos limites operacionais, destacados no parágrafo anterior. Quando ocorre um desvio entre a referência (Set-Point) e a variável de processo PV (Process Variable), também chamada de variável controlada, um sinal proporcional

ao erro (diferença) é gerado, isto é, este sinal de erro contém a informações sobre a quantidade de energia térmica (carga térmica), necessária para o restabelecimento do equilíbrio térmico do reator de XISTO. Do mesmo modo, sinais de erro ou diferença entre o Set-point e a PV são gerados para estabilização das variáveis controladas, relativas à concentração de O_2 (AIC-23001) na saída dos gases de combustão e a pressão no Header de gás combustível (PIC-23099). Na camada de otimização são gerados os sinais de controle para as variáveis manipuladas, de maneira a restabelecer a estabilidade do processo. A estratégia de controle configurada na camada de otimização é do tipo razão, ou seja, utiliza-se uma relação de proporcionalidade entre os combustíveis para posterior ajuste da concentração de O_2 . As malhas de controle das variáveis manipuladas, por sua vez, atuam na manipulação das vazões de óleo (FIC-23027), vazão de gás combustível (FIC-23028) e vazão de ar para combustão (FIC-23025).

Todavia, é importante pontuar que, em decorrência de problemas conceituais, a camada de otimização não está operacional. Com a implementação futura do controle preditivo multivariável, poderá ser suprimida a camada de otimização, uma vez que o controle MPC possui mecanismos ou algoritmo de controle capaz de realizar a otimização de acordo com os valores de referência.

Na Figura 6 é mostrado o P&ID simplificado do forno industrial e na Figura 7 é mostrada uma estrutura de controle preditivo multivariável com modelo de perturbação não medida, para implementação futura no forno industrial.

2.3 MALHA DE CONTROLE DE TEMPERATURA DO GÁS DE PROCESSO

A malha de controle de temperatura do gás de processo na saída do forno TIC-23099 é de suma importância para otimizar a produção de derivados de xisto. Essa temperatura é medida após a câmara de radiação, ou seja, na saída do gás para a retorta. A temperatura do gás de processo aquecido no forno afeta diretamente a reação de pirólise do reator de xisto (retorta). Deste modo, o controlador TIC-23099 deve manter a temperatura do gás de processo dentro dos limites operacionais definidos pelo planejamento da produção e otimização de processo.

A temperatura interna da câmara de combustão é monitorada por um conjunto de 24 termopares. A temperatura da parede externa dos tubos, situados na região de radiação, deve ser mantida entre $750^{\circ}C_{\min}$ e $80^{\circ}C_{\max}$, estes são limites mínimo e máximo estabelecidos no projeto do forno industrial. A operação do forno acima destes limites operacionais implica na deterioração dos feixes de tubos e consequentemente, diminuindo a disponibilidade operacional da planta. A demanda

de gás combustível para controle da temperatura dos gases do reciclo quente (gás de processo) é limitada pela pressão no *Header* de gás combustível. A principal função do controle de pressão do *Header* (TIC-23099) é evitar o envio de gás combustível para o sistema de tocha (*Flare*). Outros fatores restritivos (restrições de processo) devem ser levados em consideração no controle de temperatura do forno:

- Queima preferencial de gás combustível;
 - Manutenção das temperaturas de pele dos tubos da área de convecção e radiação de acordo com os limites de projeto; e
 - Manutenção do excesso de ar de combustão dentro dos limites ambientais.
-

Figura 6 – P&ID simplificado das malhas de controle do forno industrial.

Fonte: Autor.

Figura 7 – Diagrama com implementação futura do controle preditivo MPC no forno industrial.

Fonte: Autor (P&D).

A malha de controle de temperatura do gás de processo na saída do forno industrial opera em cascata, sendo TIC-23099 o controlador mestre da malha, gerando *set-point* para as variáveis manipuladas vazão de óleo combustível (FIC-23027) e vazão de gás combustível (FIC-23028), ambas liberando combustível para os queimadores do forno. No P&ID da Figura 6 as malhas de controle secundárias recebem *set-point* do controlador de temperatura TIC-23099. Há uma camada de lógica de otimização entre o controlador de temperatura TIC-23099 e as malhas das variáveis secundárias (FIC-23027 e FIC-23028), impondo restrições quanto à disponibilidade de gás e óleo. O otimizador visa maximizar o consumo de gás combustível.

2.2.2 MALHA DE CONTROLE DA CONCENTRAÇÃO DE OXIGÊNIO NOS GASES DE COMBUSTÃO

Outras variáveis controladas devem ser mantidas dentro dos limites operacionais, a saber: concentração de oxigênio nos gases de combustão (AIC-23001) e pressão de gás no *header* (tronco) (PIC-23039), de modo a manter as condições necessárias para o valor desejado de temperatura do gás de processo na saída do forno industrial. A concentração de oxigênio nos gases de combustão é uma variável controlada que reflete a relação estequiométrica entre combustível e comburente. O impacto desta variável controlada na produção de energia térmica e, conseqüentemente, na otimização do processo, é extremamente relevante, isto é, a variabilidade nesta malha de controle representa perdas monetárias e diminuição dos ciclos de operação (paradas para manutenção). O O_2 é medido por um analisador *on-line* na saída do gás de combustão (chaminé do forno). Este sinal é enviado para o controlador de excesso de ar de combustão AIC-23001, que gera *set-point* para o controlador secundário FIC-23025, que é o responsável por manipular a vazão de ar para os queimadores do forno industrial.

2.2.3 MALHA DE CONTROLE DA PRESSÃO DO TRONCO DE GÁS COMBUSTÍVEL

A pressão do tronco do gás combustível (*header* de gás) deve ser mantida de acordo com as condições de produção de gás de xisto (gás do processo), sendo a variável controlada pelo PIC-23039. O consumo de gás combustível deve ser priorizado em relação ao consumo de óleo combustível, porém a pressão do tronco do gás deve ser mantida pelo controlador PIC-23099.

É importante destacar que com a implementação futura do controle preditivo no forno, será possível reduzir significativamente a variabilidade das variáveis controladas, uma vez que a camada

de otimização será responsável por gerar as faixas de operação ou *set-point* para o controlador e este atuará nas variáveis manipuladas (FIC-23025, FIC-23027, FIC-23028).

2.2.4 VARIÁVEIS DE PERTURBAÇÃO MEDIDAS E NÃO MEDIDAS

A temperatura de gás de processo na descarga do compressor axial C-20301 pode afetar a variável controlada do TIC-23099, tratando-se, portanto, de uma perturbação não medida. A variação na temperatura do gás de processo, produz uma perturbação nas variáveis controladas do forno, ou seja, um aumento ou diminuição da temperatura de entrada de gás de processo no forno afeta a temperatura de saída (TIC-23099). Esta temperatura de descarga do compressor é acompanhada pelas rotinas de campo através da leitura do indicador TI-23067 (temperatura de descarga do gás de processo do compressor).

Durante o processamento da carga de xisto na retorta, ocorrem variações nas concentrações de óleo, poder calorífico, que são consideradas perturbações não medidas, em função dos efeitos produzidos nas variáveis controladas do forno. O reator do processo PETROSIX® (Retorta), recebe continuamente a carga de xisto minerado, para produção de gás e óleo combustível, e subprodutos (enxofre, nafta, etc).

Todavia, com a evolução da tecnologia do processo PETROSIX®, foi incorporado uma nova entrada de carga para a Retorta. Trata-se da alimentação de óleo de resíduo de vácuo (lastro), porém não medida. Esta nova configuração operacional tem como principal objetivo, promover a conversão dos resíduos de vácuo em óleo combustível para navios (*Bunker Oil*). A injeção de resíduo de vácuo no reator tem como efeito, elevação da produção de óleo e gás, variações das concentrações e poder calorífico dos componentes do gás de processo, afetando diretamente as variáveis controladas do forno industrial.

Além das perturbações não medidas destacadas nos parágrafos anteriores, o forno é afetado pela variação da vazão de processo (gás xisto), considerada neste caso, como perturbação medida. O gás de processo produzido na retorta (reator), com temperatura de saída situada em torno de 160°C, é direcionado para o forno (entrada) onde receberá um incremento de temperatura, isto é, o gás de processo será aquecido e sairá com uma temperatura de aproximadamente 560°C. As variações na vazão e temperatura de entrada do gás de processo provocam uma perturbação nas variáveis controladas do forno, por esta razão, esta variável foi incluída no processo de pré-identificação e identificação do modelo da planta, fazendo parte dos modelos identificados.

CAPÍTULO 3

PREPARAÇÃO PARA OS TESTES DE PRÉ-IDENTIFICAÇÃO E IDENTIFICAÇÃO DO MODELO

Neste capítulo é descrito o planejamento para a identificação do modelo matemático do forno industrial de 50 MW. Este equipamento caracteriza-se pela sua relevância na produção de energia térmica para o reator do processo PETROSIX®. O planejamento do experimento compreende todas as etapas necessárias para os testes de identificação.

3.1 PLANEJAMENTO DO EXPERIMENTO DE PRÉ-IDENTIFICAÇÃO

O controle preditivo, objeto de pesquisa desta tese, é uma classe de algoritmos computacionais de controle que usa um modelo explícito do processo para obter previsões da resposta futura da planta. A cada intervalo de controle, o algoritmo MPC determina a sequência de variáveis manipuladas $u(t)$, $u(t+1) \dots u(t+h)$, ajustadas para otimizar o comportamento futuro do processo (QIN; BADGWELL, 2003). Assim, para o desenvolvimento do projeto de controladores MPC, é necessário *a priori* ter disponível o modelo matemático que explicita a dinâmica do processo, de modo a possibilitar a predição das ações de controle futuras. O modelo matemático é incorporado na estrutura do controlador, fazendo parte do algoritmo que executa as ações de controle, isto é, o controlador altera o comportamento dinâmico da planta, de acordo com os objetivos pré-estabelecidos, tais como: otimização de custo, maximização da produção, manutenção da qualidade de produto e sustentabilidade ambiental. Portanto, a identificação de sistemas é fundamental na implantação do controle preditivo.

Uma série de algoritmos, como os de controle preditivo e controle robusto, além de ferramentas de otimização em tempo real, dedicam boa parte de seus esforços para obter formas adequadas de descrever os sistemas que se deseja controlar ou otimizar. É relevante destacar que há um custo associado a isto, que em plantas complexas, demanda tempo e mão de obra especializada para o planejamento e testes de identificação (DARBY; NIKOLAOU, 2012). No projeto de um controlador preditivo multivariável, a etapa de identificação do modelo matemático demanda um tempo de preparação para a execução dos testes. Segundo Darby e Nicolaou (2012), as etapas de

modelagem, realização de experimentos e estimação dos parâmetros são responsáveis pela maior parte da quantidade de homens-hora aplicada no projeto.

A identificação de sistemas consiste em gerar sinais conhecidos, de modo a perturbar o processo, visando obter uma representação matemática do comportamento dinâmico da planta, em resposta aos sinais de excitação. De acordo com Aguirre (2004), a identificação de sistemas tem como objetivo a obtenção de modelos matemáticos que expliquem, pelo menos em parte e de forma aproximada, a relação de causa e efeito presente nos dados do sistema ou processo.

Existem duas metodologias para a obtenção de modelos em sistemas físicos e químicos, que são: metodologia empírica e metodologia analítica. A metodologia empírica, conhecida como metodologia experimental de processos, é um procedimento que consiste em submeter as entradas da planta a uma excitação ou perturbação do tipo: degrau³, pulso⁴, senoidal⁵. Com base nos sinais coletadas (resposta da planta), realiza-se a análise dos dados, determinação das equações e correlações do modelo. O outro processo de modelagem é a metodologia analítica ou fenomenológica, que é pautada na busca das equações diferenciais e algébricas que compõem o modelo, sendo fundamentada nas leis da Física, Química e Físico-Química (AGUIRRE, 2014).

Na identificação de sistemas, o sinal de excitação é aplicado em um conjunto de variáveis manipuladas, chamadas de entradas. Uma vez aplicada a excitação no processo, são medidas as excitações e as respostas produzidas no transcorrer do tempo. A partir dos dados coletados (entradas e saídas), busca-se uma função matemática, que explicita as correlações entre as variáveis de entrada e saída, que são chamadas de modelo. No processo de identificação do forno industrial petroquímico do processo PETROSIX®, foi aplicada a metodologia de resposta ao degrau para obter um pré-modelo e depois um sinal binário aleatório do tipo *PRBS* para obter o modelo final. Trata-se de uma técnica consolidada, que apresenta resultados satisfatórios e que permite obter um conjunto de dados significativos, que retrata a dinâmica do processo.

Cabe destacar que o tipo de excitação aplicada ao processo afeta diretamente o modelo identificado. Assim, o projeto de um sinal ótimo consiste em definir quais sinais de excitação serão utilizados. Estas excitações ou perturbações podem ser executadas em dois modos de operação: em malha aberta, caracterizada pela inexistência de controladores, em que as ações de controle são aplicadas de forma isolada, com os controladores em modo manual e em malha fechada, na qual o controlador da planta é mantido ativo (modo automático) ao longo dos testes de identificação.

³ Sinal com amplitude variável entre limites pré-definidos, de maneira súbita. (SEBORG *et al.*, 2011).

⁴ Variação da amplitude do sinal, iniciando de um valor de referência, alcançando outro e retornando de forma imediata (SEBORG *et al.*, 2011).

⁵ Variação da amplitude de um sinal com curva de trajetória senoidal (SEBORG *et al.*, 2011).

Em relação à pré-identificação do modelo matemático do forno industrial, foram seguidas as etapas mostradas no fluxograma da Figura 8.

1. Projeto do experimento. Definição das variáveis de entrada e saída que comporão o modelo, buscando *a priori*, a relação causa e efeito. Nesta etapa se define também a duração do experimento, o intervalo de amostragem das variáveis sendo medidas, a forma do sinal de excitação, incluindo seu formato e suas características temporais.
2. Realização dos experimentos. Consiste no teste dinâmico e coleta de dados, também conhecido como teste de identificação ou experimento de identificação.
3. Seleção da estrutura do modelo. Nesta etapa é feita a seleção da estrutura do modelo e da sua ordem. Basicamente, a seleção da estrutura e da ordem corresponde à seleção do número de polos e zeros e do tempo morto. Os dados da planta, coletados durante os experimentos, serão manipulados em um ambiente computacional, através de uma sequência numérica discreta. Todo o conhecimento e informações sobre a planta, combinado com as particularidades matemáticas dos modelos, são importantes para auxiliar na determinação do modelo.
4. Estimação dos parâmetros. *A priori* seleciona-se o algoritmo de estimação. O algoritmo utilizado com maior frequência nos processos de estimação de parâmetros é o dos mínimos quadrados (*Least Squares*).
5. Validação do modelo. O modelo necessita ser validado, isto é, ele deve retratar com precisão a dinâmica do forno industrial. Por esta razão, deve-se ter o conhecimento do objetivo da aplicação e suas propriedades, de modo a permitir a decisão se o modelo em questão atende as características do sistema real. Caso o modelo não seja validado, é necessário repetir os procedimentos de identificação. Estes passos podem conduzir desde a revisão da amplitude dos sinais de excitação, métodos de estimação dos parâmetros, problema numérico, conjunto de dados insuficiente.

Todos os elementos do experimento de pré-identificação do processo destacados no texto, são de suma importância para a obtenção de dados representativos da planta. Contudo, é pertinente pontuar que, para atingir o objetivo desta fase, procurou-se dirimir dúvidas relativas ao experimento, tais como: tempo necessário para acomodação da planta, ações corretivas e mitigadores para evitar problemas de parada de emergência, perdas de produção e descaracterização dos produtos (especificação). Todos estes pontos foram objetos de avaliação por parte de uma equipe multifuncional.

O resultado deste planejamento foi a identificação de ações mitigadores, de maneira a evitar possíveis não conformidades relacionadas com o processo. Não estão inclusos no escopo deste

trabalho a descrição detalhada do fluxograma de pré-identificação de sistemas. Todas as etapas do experimento de pré-identificação estão apresentadas de maneira resumida na pois o objetivo principal é expor a sequência que foi usada para identificação da planta, que é o objeto de estudo desta tese.

Figura 8 – Fluxograma do processo de pré-identificação do modelo matemático.

Fonte: (SÖDERSTRÖM; STOICA, 1989).

3.1.1 PRÉ-IDENTIFICAÇÃO COM SINAL EXCITAÇÃO DO TIPO DEGRAU

O estímulo utilizado na pré-identificação é do tipo degrau. Esse estímulo força uma resposta que permite extrair parâmetros da dinâmica do processo, tais como, tempo morto, ganho em regime estacionário e constante de tempo. Se for aplicado um duplo degrau, sendo um positivo e outro negativo, é possível explorar de forma simétrica a região de operação do sistema e verificar a presença de não linearidades. Usualmente, esse tipo de sinal tem o formato de uma onda quadrada, que consiste em dois degraus consecutivos, de sentidos opostos e mesma amplitude, ou ainda tendo o segundo uma amplitude duas vezes maior que o primeiro, mas em sentido oposto. Este sinal concentra energia nas baixas frequências, e, conseqüentemente, os modelos obtidos utilizando apenas este tipo de perturbação possuem uma distorção na distribuição de incertezas, sendo mais precisos nesta região (ISERMANN; MÜNCHHOF, 2011).

Por esta razão os dados obtidos na pré-identificação, sendo que na identificação propriamente dita serão utilizados para o teste de identificação do modelo final do forno, utilizando sinais PRBS - sinal binário pseudo-aleatório (*Pseudo-Random Binary Sequence*).

3.2 PLANEJAMENTO DO EXPERIMENTO DE IDENTIFICAÇÃO DO FORNO COM SINAIS PRBS

Parte-se do princípio que já se conhece o conjunto de variáveis controladas e manipuladas e as perturbações medidas. O experimento deve ser planejado buscando definir a maior amplitude de excitação possível. Em plantas reais, a amplitude dos sinais de excitação na entrada do processo é limitada pelas características dinâmicas do sistema. É preciso manter os sinais de excitação dentro dos limites de operação do processo. A duração do experimento deve ser negociada com as equipes de operação e engenharia de otimização de processo, e segurança e meio ambiente (SMS), visando minimizar o tempo de perturbação da planta e, conseqüentemente, a probabilidade de impactar na especificação de produtos e produção.

Os requisitos de tempo e amplitude dos testes são considerados relevantes para nortear o projeto de identificação do modelo ou conjunto de modelos que retratem a dinâmica do processo (ZHU *et al.*, 2013). Todavia, é pertinente destacar que os limites dos sinais de excitação foram determinados com base nos limites de operação do forno e retorta, limites dos atuadores (válvula de

controle, *dampers* e equipamentos rotativos). É importante no projeto dos sinais de excitação estabelecer amplitudes mínimas, suficientes para excitar as saídas do processo.

Para identificar o modelo do forno, o sinal de excitação aplicado teve uma amplitude de cerca de 5% a 8% do valor nominal das variáveis manipuladas. Estes sinais foram aplicados com o processo em regime estacionário. Esta amplitude foi usada tanto na geração dos degraus para gerar os pré-modelos quanto na geração dos sinais *PRBS* para obter os modelos. Os sinais de excitação foram aplicados nas entradas u_r do processo, isto é, nas variáveis manipuladas (LARROTA; BOMBARDELLI; GARCIA, 2014).

O primeiro degrau foi no sentido de elevar a amplitude dos *set-point* para um valor superior, segundo o planejado (5% a 8%). Após o período de acomodação da planta (regime estacionário), os *set-point* voltaram para a amplitude anterior ao início do teste, aguardou-se a acomodação do processo e excitou-se a planta em sentido oposto, com a mesma amplitude aplicada no sentido positivo. Em todas as etapas de aplicação da excitação nas entradas da planta, acompanhou-se a resposta do processo nas saídas y_p , visando evidenciar o comportamento do sistema e garantir que os sinais sejam aplicados somente na condição de regime estacionário. Estes sinais em degrau foram usados na pré-identificação, para criar pré-modelos do processo.

Conforme destacados nos parágrafos anteriores, a partir dos dados (tempo morto, constante de tempo, ganho em regime estacionário) obtidas na pré-identificação, utilizou para projetar os sinais *PRBS*. Os sinais *PRBS* (*Pseudo-Random Binary Sequence* ou sequência binária pseudo-aleatória) foram aplicados em cada entrada, para gerar os dados para a identificação do modelo. Por se tratar de um processo multivariável, ou seja, com múltiplas entradas e múltiplas saídas (MIMO), os sinais de excitação foram aplicados nas entradas, simultaneamente.

Os sinais *PRBS* aplicados no *Set-point* das variáveis manipuladas, podem assumir somente dois valores, isto é, nível alto e nível baixo. Entretanto, estes níveis de sinais devem ser mantidos em períodos distintos, em cada valor aleatoriamente. De forma diferente em relação ao degrau, o tempo de permanência do sinal em cada nível apresenta um limite mínimo e um limite máximo os quais são matematicamente determinados (TULLEKEN, 1990).

A Figura 9 mostra a forma de onda dos sinais *PRBS*, aplicados na variáveis manipuladas, para identificação do modelo matemático do forno. Estes sinais foram aplicados em malha fechada, alterando os valores da referência (*set-point*) mantendo a amplitude constante. Estas excitações (sinais do tipo degrau e *PRBS*) produzem uma diferença (erro) entre a referência e a variável controlada e,

por consequência, o controlador atua no sistema, gerando perturbações que efetivamente serão aplicadas no processo (forno).

Figura 9 - Sinais de excitação PRBS utilizado para identificação do modelo matemático do forno.

Fonte: Autor

A seleção do sinal *PRBS* para a identificação do sistema, deve-se ao fato que este tipo de sinal apresenta uma capacidade de estimular uma longa faixa de frequências com elevada excitação, o que o torna adequado para identificação, por enriquecer as informações do sinal de resposta da planta (LJUNG, 2002). No Capítulo 5 é descrito em detalhes o processo de identificação da planta com sinais de excitação do tipo *PRBS*.

Na fase de planejamento do experimento de identificação do forno, realizaram-se as seguintes atividades:

1. Calibração de todos os instrumentos de medição das variáveis selecionadas (variáveis controladas, manipuladas e perturbações medidas);
2. Verificação do desempenho das válvulas de controle, com o objetivo de identificar algum problema relacionado com agarramento;
3. Avaliação da sintonia dos controladores PID. Como o sistema foi identificado em malha fechada, antes da implementação do experimento, foram verificadas as sintonias de todos os controladores PID e ajustados os parâmetros de sintonia dos reguladores que apresentaram um comportamento indesejável (*overshoot*);

4. Desabilitado o modo de exceção e compressão do *PI* (*Plant Information*) de todo o conjunto de variáveis previamente selecionadas; e
5. Reconfigurado o intervalo de amostragem do Sistema Digital de Controle Distribuído (SDCD) e do *PI* para 1 segundo.

Após a conclusão do experimento, realizou-se a inspeção visual dos dados coletados, com o propósito de identificar alguma descontinuidade, inconsistência entre amplitude das excitações aplicadas e a correspondência com a indicação no historiador (*TimeStamp*⁶).

Todavia, independente da metodologia selecionada, para resolução do problema de interesse prático (identificação da planta), o importante é serem definidos parâmetros estimáveis para melhor adequar o modelo à realidade experimental encontrada (forno). Neste trabalho buscou-se obter modelos do processo e posterior validação, isto é, onde os modelos encontrados são submetidos a diversas formas de avaliação com o propósito de se determinar a adequação do mesmo à realidade observada.

⁶ *TimeStamp* é uma marca temporal ou estampa de tempo. Trata-se de um conjunto de caracteres denotando a hora ou data que certo evento ocorreu (COULOURIS *et al.*, 2013).

CAPÍTULO 4

PRÉ-IDENTIFICAÇÃO

Neste capítulo são exibidas as etapas realizadas durante o experimento de pré-identificação e a formulação do modelo matemático da planta. É parte deste capítulo a identificação dos modelos relacionados com as variáveis de processo, seleção e validação dos modelos e apresentação do modelo que representa as características dinâmicas do forno industrial.

4.1 PRÉ-IDENTIFICAÇÃO DO FORNO INDUSTRIAL

Este capítulo descreve como gerar o modelo matemático a ser usado no controlador preditivo, intitulado “ M_{MPC} ” (*Model Predictive Control with Non-Measured Disturbance*). É importante citar que se trata de uma planta suscetível a distúrbios não medidos, em que o modelo obtido incorpora os modelos de perturbações não medidas. As perturbações medidas, identificadas no experimento, serão usadas em um projeto futuro, pois não está contemplada neste trabalho a incorporação do controle antecipatório (*feedforward*) no controlador MPC, para as perturbações medidas. Os dados usados foram obtidos a partir da resposta da planta a sinais de excitação do tipo degrau. As excitações foram geradas em uma variável manipulada por vez. Neste capítulo são disponibilizados os modelos de cada variável controlada. Além da seleção dos modelos aptos para uso, é indicado qual é o melhor modelo para a aplicação, neste caso, para o controle preditivo. Os modelos finais apresentados contêm os melhores resultados obtidos.

4.2 EXECUÇÃO DO EXPERIMENTO DE IDENTIFICAÇÃO

Após a fase de planejamento dos testes, o experimento foi realizado, de acordo com a sequência descrita a seguir:

1. Aplica-se um degrau positivo na primeira variável manipulada (de SP0 + DSP) sendo DSP de aproximadamente 5% a 8% e acompanha-se o comportamento da saída do processo após a aplicação do sinal de excitação (degrau);
-

-
2. Aguarda-se que todas as variáveis da unidade estabilizem, ou seja, espera-se um tempo para que o processo entre em regime estacionário, incluindo as variáveis que não estavam sendo identificadas. Cabe citar que a orientação para aguardar o tempo de estabilização da planta é em razão da estimativa dos ganhos do modelo;
 3. Aplica-se um degrau negativo na mesma variável manipulada (de $SP_0 - DSP$);
 4. Aguarda-se o tempo de estabilização da planta, isto é, a acomodação de todas as variáveis do processo.
 5. Aplica-se um degrau negativo na mesma variável manipulada (de $SP_0 - DSP$);
 6. Aguarda-se o tempo de estabilização de todas as variáveis da planta;
 7. Retorna-se a variável manipulada para o valor inicial (de $SP_0 + DSP$). Repete-se o procedimento de tempo de acomodação para todas as variáveis da planta (processo em regime estacionário).

Esta sequência foi repetida para cada variável manipulada, previamente selecionada, sendo que se procurou executar o experimento em um período ininterrupto.

4.3 TRATAMENTO DOS DADOS

A primeira etapa para a pré-identificação do modelo do processo foi o tratamento de dados. Esta fase consistiu em realizar a filtragem, normalização e reamostragem dos dados obtidos da planta. O objetivo desta etapa foi a busca pelos melhores resultados nos algoritmos de pré-identificação. A Figura 10 mostra os dados obtidos no experimento de pré-identificação.

Figura 10- Dados obtidos do experimento de pré-identificação do forno industrial.

Figura: Autor.

4.3.1 FILTRAGEM DOS DADOS COLETADOS

O processo de filtragem foi uma das fases do tratamento de dados. Em razão dos controladores PID operarem em modo cascata (configuração mestre-escravo), foi necessário executar a filtragem das variáveis manipuladas. Para a filtragem dos dados, utilizou-se um filtro Butterworth⁷ de fase 0. Como o filtro Butterworth é analógico utilizou-se um filtro IIR como protótipo para pré-filtragem dos dados. Existem diversos métodos de filtragem de dados, porém, não é o propósito desta seção abordar a revisão bibliográfica sobre este tema.

A Figura 11 mostra os resultados obtidos em relação ao processo de filtragem. Por questão de simplicidade, são exibidos apenas os resultados para a pré-identificação da TIC-23099, as demais variáveis controladas apresentaram resultados muito similares.

⁷ Os filtros Butterworth foram descritos primeiramente pelo engenheiro britânico S. Butterworth. Foi desenvolvido de modo a obter uma resposta em frequência o mais plana, o quanto for matematicamente possível na banda passante. A resposta em frequência de um filtro Butterworth não possui *ripple* ou ondulações na banda passante e se aproxima do zero na banda rejeitada (OPPENHEIM; SCHAFER, 1998).

Figura 11 - Dados filtrados da variável controlada TIC-23099.

Fonte: Autor.

4.3.2 NORMALIZAÇÃO DOS DADOS

Em seguida, os dados foram normalizados em uma faixa de -0,5 a 0,5. Os resultados do processo de normalização são vistos na Figura 12. O modelo usado para a normalização foi por desvio padrão, em que a média μ é retirada do conjunto de dados de cada variável e o resíduo é dividido pelo desvio padrão. Por esta razão, o intervalo ou faixa dos dados normalizados situa-se em torno de zero. Na Tabela 4 são exibidos os dados normalizados no ponto de operação da planta.

Figura 12 – Normalização dos dados.

Fonte: Autor.

Tabela 4 – Dados normalizados do conjunto de variáveis em torno do ponto de operação.

<i>Variável</i>	<i>Ponto de Operação</i>
Variáveis Controladas	
Y1 – TIC 23099	557
Y2 – PIC 23039	5,1
Y3 – AIC 23001	3,14
Variáveis Manipuladas	
U1 – FIC 23028.SP	2412
U2 – FIC 23025.SP	52686
U3 – FIC 23027.SP	688
Perturbação Medida	
FIC 23003	160

Fonte: Autor.

4.3.3 REAMOSTRAGEM DOS DADOS IDENTIFICADOS

Na grande maioria das plantas petroquímicas, as variáveis são adquiridas e armazenadas por um sistema digital de controle (*Distributed Control System*). Para a etapa de pré-identificação dos modelos, é preciso que estas variáveis sejam amostradas. A frequência de amostragem, segundo o teorema de Shannon, deve ser de 2 a 10 vezes superior à frequência de interesse (SHANNON, 1948). Este procedimento visa minimizar a perda de informações devida à seleção do tempo de amostragem das variáveis. Trata-se da fase final dos procedimentos de tratamento dos dados. O conjunto de dados foi reamostrados para um intervalo de amostragem de 1 minuto. O resultado da reamostragem é exibido na Figura 13. Cabe destacar que, através de uma análise prévia, posterior à reamostragem, observou-se que foram mantidas ou preservadas todas as características dos sinais, mesmo com a redução da taxa de amostragem pelo fator de 60.

Figura 13 – Dados reamostrados – intervalo de amostragem de 1 minuto.

Fonte: Autor.

Não obstante, é oportuno destacar que existem várias técnicas determinísticas ou probabilísticas para o processamento dos sinais coletados (dados) mantendo o objetivo principal desta etapa, ou seja, mantendo representatividade e ⁸granularidade das amostras coletadas, minimizando as perdas de informação.

⁸Granularidade (grão) de dados refere-se ao nível de detalhe em que os dados são armazenados, ou seja, tamanho e conformidade com a necessidade ou características da aplicação (ANTONIOU, 2006), (BATISTA, 2003).

4.4 ANÁLISE DE CORRELAÇÃO DAS VARIÁVEIS

A matriz de correlações cruzadas foi utilizada para a análise do acoplamento (correlação) entre as variáveis de processo. Através desta propriedade, foi possível identificar a causalidade entre as alterações em uma das variáveis de entrada e o resultado das alterações nas variáveis de saída. Trata-se de uma matriz bidimensional, composta por variáveis correlacionadas entre si, onde é possível visualizar, de imediato, as potenciais correlações entre as variáveis envolvidas. A análise de correlação é uma técnica que, tem como propósito estimar uma relação que possa existir entre duas variáveis observáveis, isto é, a correlação resume o grau de relacionamento entre duas variáveis. O principal objetivo da aplicação da análise correlacional é determinar ou mensurar o grau de relacionamento entre duas variáveis, sendo medido através do coeficiente de correlação linear de *Pearson*. Neste trabalho utilizou-se algoritmos computacionais para determinar a correlação entre as variáveis identificadas. Todavia, pode-se realizar análise correlacional ou o comportamento entre duas variáveis através de gráficos de dispersão que, contribui de algum modo para entendimento do fenômeno estudado (TINSLEY; BROWN, 2000).

Para a elaboração da matriz de correlação, utilizou-se o algoritmo de regressão linear. Tabela 5 mostra a matriz de correlação entre as variáveis de entrada e saída do processo.

Tabela 5 - Matriz de correlação das variáveis do processo.

		<i>Entradas</i>			
		FIC 23028 SP	FIC 23025 SP	FIC 23027 SP	
<i>Saídas</i>	TIC 23099	X	X	X	
	PIC 23039	X	X	0	
	AIC 23001	X	X	X	

Fonte: Autor.

Os pares das variáveis de entrada e saída indicados com a letra ‘X’ explicitam os pares de variáveis para os quais existe correlação entre os dados. As variáveis correlacionadas indicam a possibilidade de identificar um modelo e os pares indicados com ‘0’, sinalizam que não é observada correlação e aonde não foi identificado um modelo, ou seja, a entrada não afeta a saída referida.

4.5 PRÉ-IDENTIFICAÇÃO DO MODELO DA VARIÁVEL Y-1 TIC-23099

A variável TIC-23099 corresponde à temperatura de gás de processo na saída do forno industrial. Para esta variável foram obtidos três bons modelos: dois modelos ARX e um modelo ARMAX, descritos na sequência. O modelo avaliado como melhor é o modelo ARX 1. É pertinente destacar que, todos os modelos identificados, têm taxa de amostragem de 1 minuto.

4.5.1 VALIDAÇÃO DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

A validação tem como objetivo avaliar a capacidade de predição do modelo identificado. O processo de validação dos modelos matemáticos tem como objetivo avaliar a precisão do modelo em função dos objetivos pré-estabelecido. A etapa de validação dos modelos consiste em comparar os resultados das saídas simuladas dos modelos identificados com os dados reais da planta, através de métodos estatísticas, inspeção visual (técnica heurística⁹) e análises no domínio da frequência. Na sequência são apresentados os modelos validados para TIC-23099. A Figura 14 apresenta as predições do modelo para 1 passo à frente e na Figura 15 apresentam-se as predições resposta livre.

Cabe ressaltar que, para a identificação utilizou-se 70% dos dados disponíveis e 30% foi aplicado para validação dos modelos.

⁹ A capacidade heurística é uma característica humana para descobrir ou resolver problemas a partir da experiência prática, da observação e da criatividade. Heurísticas são processos cognitivos empregados em decisões não racionais, sendo definidas como estratégias que ignoram parte da informação com o objetivo de tornar ágil a seleção de resultados. Podem ser algoritmos exploratórios que buscam resolver problemas geralmente não envolvem a implementação computacional de um conhecimento especializado (BUENO, 2009).

Modelo ARX 1**FIC-23028****FIC-23025****FIC-23027****FIC-23003**

$$G(z) = \left[\frac{0.002017 z^{-1}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} \quad \frac{-3.566e-05 z^{-6}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} \quad \frac{0.001671 z^{-2}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} \quad \frac{-0.04359 z^{-1}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} \right]$$

Perturbação não medida $H(z) = \frac{0.002991}{1 - 1.723 z^{-1} + 0.7384 z^{-2}}$

Modelo ARX 2**FIC-23028****FIC-23025****FIC-23003****FIC-23027**

$$G(z) = \left[\frac{0.0009336 z^{-1}}{1 - 2.474 z^{-1} + 2.295 z^{-2} - 0.9574 z^{-3} + 0.1435 z^{-4}} \quad \frac{-2.039e^{-5} z^{-3}}{1 - 2.474 z^{-1} + 2.295 z^{-2} - 0.9574 z^{-3} + 0.1435 z^{-4}} \right]$$

$$\left[\frac{0.000822 z^{-3}}{1 - 2.474 z^{-1} + 2.295 z^{-2} - 0.9574 z^{-3} + 0.1435 z^{-4}} \quad \frac{-0.01579 z^{-1}}{1 - 2.474 z^{-1} + 2.295 z^{-2} - 0.9574 z^{-3} + 0.1435 z^{-4}} \right]$$

Perturbação não medida $H(z) = \frac{0.002489}{1 - 2.474 z^{-1} + 2.295 z^{-2} - 0.9574 z^{-3} + 0.1435 z^{-4}}$

Modelo ARMAX**FIC-23028****FIC-23025****FIC-23027****FIC-23003**

$$G(z) = \left[\frac{0.001647 z^{-2}}{1 - 1.721 z^{-1} + 0.736 z^{-2}} \quad \frac{-2.736e^{-5} z^{-5}}{1 - 1.721 z^{-1} + 0.736 z^{-2}} \quad \frac{0.001304 z^{-3}}{1 - 1.721 z^{-1} + 0.736 z^{-2}} \quad \frac{-0.01663 z^{-1} - 0.01538 z^{-2}}{1 - 1.721 z^{-1} + 0.736 z^{-2}} \right]$$

Perturbação não medida $H(z) = \frac{0.002774 + 0.001665 z^{-1}}{1 - 1.721 z^{-1} + 0.736 z^{-2}}$

Figura 14 - Validação dos modelos com relação à sua capacidade de predição um passo à frente.

Fonte: Autor.

Figura 15 - Predições do modelo, resposta livre.

Fonte: Autor.

Através da análise da resposta dos modelos, conclui-se que os três têm excelente capacidade de predição 1 passo à frente e capacidades de predição muito similares para a simulação livre. Os erros de predição são exibidos na Figura 16. Na avaliação dos erros de predição, observa-se um comportamento normal dos erros, para todos os horizontes de predição.

Figura 16 - Erros de predição.

Fonte: Autor.

As Figura 17 e Figura 18 apresentam o comportamento do índice *fit* dos modelos para diversos passos à frente.

Figura 17 - *Spider plot* dos índices *fit* para diversos horizontes de predição.

Fonte: Autor.

Figura 18 – Y1 – Distribuição dos índices fit para diversos horizontes de previsão.

Fonte: Autor

A capacidade de previsão dos modelos decai com o horizonte de previsão, como esperado. Nota-se ainda que o modelo de perturbação tem efeito até o horizonte de previsão de 30 minutos e as previsões se comportam praticamente como simulação livre para horizontes maiores.

4.5.2 VALIDAÇÃO DE THEIL DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

O índice de Theil é uma medida estatística, sendo dado pelo logaritmo neperiano da razão entre as medidas aritméticas e geométricas do conjunto de dados. Se a razão entre as medidas for igual a 1, Theil será igual a zero, indicando perfeita distribuição. Quanto maior a razão entre as medias, maior será valor para o índice de Theil, e consequentemente, pior será a distribuição (ZELLNER; THEIL, 1962). De acordo com Zellner e Theil (1962), o método pode ser entendido como o método dos mínimos quadrados ordinários (*MSE - Mean Squared Error*). No método *MSE* os erros com maior amplitude são penalizados e os erros com sinais negativos não são cancelados. Todavia, este método não consegue decompor as fontes dos erros. O método proposto por Zellner e Theil (1962) destaca as fontes do erro. Estas fontes do erro são explicitadas na forma de *bias* (tendência, inclinação), da variância e da covariância. Para a validação dos modelos identificados é utilizado o coeficiente de desigualdade de Theil, também conhecido como *TIC (Theil Coefficient Inequality)* (VAN WOENSEL; WUYTS; VANDAELE, 2006).

A validação de Theil também avalia a capacidade de predição dos modelos, sendo um complemento ao índice *fit*. A Figura 19 exibe a distribuição dos índices de Theil para diversos horizontes de predição. Valores menores são melhores, isto é, o valor do *TIC* varia entre 0 e 1 sendo que, o índice 0 significa predições perfeitas e 1 piores predições.

Figura 19 - Y1 – Distribuição dos índices de Theil para diversos horizontes de predição.

Fonte: Autor.

Observa-se melhor nesta validação a diferença de comportamento entre os modelos, caracterizando o modelo ARX 1 com a melhor qualidade.

4.5.3 ANÁLISE DE RESÍDUOS DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

A análise de resíduos observa os resíduos de predição do modelo. São feitas uma análise de correlação, uma modelagem de resposta ao impulso e uma análise em frequência dos resíduos, exibidas nas Figura 20 e 21. Observa-se na Figura 20 que os resíduos permanecem dentro das regiões de confiabilidade para todos os valores de atraso de todos os modelos, validando-se ambos os modelos. Na resposta ao impulso dos resíduos, exibida na Figura 21, os modelos apresentaram resultados similares. Observa-se na resposta em frequência dos resíduos na Figura 22, resultados muito similares para ambos os modelos. Pontua-se que os erros são maiores em frequências mais altas, o que se deve à natureza dos sinais de onda quadrada utilizados na excitação da planta, porém, não inviabiliza o uso do modelo identificado.

Figura 20 – Y1 - Análise de correlação dos resíduos.

Fonte: Autor.

Figura 21 – Y1 - Resposta ao impulso dos resíduos.

Fonte: Autor.

Figura 22 – Y1 – Resposta em frequência dos resíduos.

Fonte: Autor.

4.5.4 ANÁLISE DE GANHOS DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

A Figura 23 mostra os ganhos dos modelos selecionados, assim como suas médias e desvios padrão. Observa-se que os três modelos apresentam ganhos similares, podendo ser igualmente utilizados segundo este critério de validação.

Resposta da TIC-23099 para as manipuladas: FIC-23028.SP, FIC-23025.SP, FIC-23027.SP e FIC-23003, na ordem em que foram identificadas:

$$[0.31 \text{ ARX e } 0.4 \text{ ARMAX} \quad 0.15 \text{ ARX e } 0.25 \text{ ARMAX} \quad -0.001 \text{ ARX} \quad 0.3 \text{ ARMAX e } 0.19 \text{ ARX}]$$

Figura 23 - Y1 – Ganhos estacionários.

Fonte: Autor.

4.5.5 VALIDAÇÃO PELO *ERROR BOUND* DOS MODELOS DA VARIÁVEL Y1 TIC-23099

A validação pela função estatística *Error Bound* permite uma análise em frequência da incerteza do modelo, classificando a sua qualidade por bandas de frequência. A Figura 24 exibe o *Error Bound* para os modelos identificados. Há uma incerteza no domínio da frequência para esses modelos, devido ao sinal de excitação usado, o que é esperado com ondas quadradas.

Figura 24 - Y1- Validação através do *Error Bound*.

Fonte: Autor.

4.5.6 MAPA DE POLOS E ZEROS DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

A Figura 25 mostra o mapa de polos e zeros dos modelos identificados.

Figura 25 - Y1- Mapa de polos e zeros.

Fonte: Autor.

4.5.7 RESPOSTA EM FREQUÊNCIA DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

A Figura 26 exibe as respostas em frequência dos modelos identificados, caracterizando-os no domínio da frequência.

Figura 26 - Resposta em frequência.

Fonte: Autor.

4.5.8 RESPOSTA AO DEGRAU DOS MODELOS DA VARIÁVEL Y-1 TIC-23099

A Figura 27 mostra a resposta ao degrau dos modelos de processo identificados e a Figura 28 exibe as respostas ao degrau dos respectivos modelos de perturbação. São indicados os tempos de acomodação de cada modelo.

Figura 27 - Resposta ao degrau dos modelos do forno industrial.

Fonte: Autor.

Figura 28 - Y1 – Respostas ao degrau dos modelos de perturbação identificados.

Fonte: Autor.

4.6 PRÉ-IDENTIFICAÇÃO DO MODELO DA VARIÁVEL Y-2 PIC-23039

A segunda variável controlada identificada foi a pressão no *header* de Gás Combustível, PIC-23039, para a qual foram obtidos dois modelos bons: um modelo ARX e um modelo ARMAX, descritos a seguir. O modelo avaliado como melhor é o modelo ARMAX. Todos os modelos têm taxa de amostragem de 1 minuto. Na sequência são apresentados os modelos validados da PIC-23039.

4.6.1 VALIDAÇÃO DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

As validações dos modelos satisfatórios são exibidas nas subseções seguintes. A validação pelo índice *fit* avalia a capacidade de predição do modelo identificado. A Figura 29 exhibe as predições do modelo para 1 passo à frente e a Figura 30 expõe as predições livres dos modelos.

Modelo ARX

FIC-23028

FIC-23025

FIC-23027

FIC-23003

$$G(z) = \left[\frac{1.825e^{-5} z^0 - 1}{1 - 1.879 z^{-1} + 0.8844 z^{-2}} \quad \frac{1.13e^{-6} z^{-23} - 1.21e^{-6} z^{-24}}{1 - 1.879 z^{-1} + 0.8844 z^{-2}} \quad 0 \quad \frac{0.001838 z^{-5}}{1 - 1.879 z^{-1} + 0.8844 z^{-2}} \quad \frac{-0.00099 z^{-4} + 0.000640 z^{-5} - 0.000664 z^{-6}}{1 - 1.879 z^{-1} + 0.8844 z^{-2}} \right]$$

$$\text{Perturbação não medida } H(z) = \frac{0.002491}{1 - 1.879 z^{-1} + 0.8844 z^{-2}}$$

Modelo ARMAX

FIC-23028

FIC-23025

FIC-23003

FIC-23027

$$G(z) = \left[\frac{4.716e^{-6} z^{-1}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}} \quad \frac{-8.228e^{-7} z^{-47} + 1.076e^{-6} z^{-48} - 2.949e^{-7} z^{-49}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}} \quad 0 \quad \frac{0.0003432 z^{-4} - 0.00228 z^{-5} + 0.003633 z^{-6} - 0.002067 z^{-7}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}} \right]$$

$$\text{Perturbação não medida } H(z) = \frac{0.002951 - 0.002226 z^{-1}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}}$$

Figura 29 - Y2 - Predições 1 passo à frente.

Fonte: Autor.

Figura 30 - Y2 - Predições infinitos passos à frente.

Fonte: Autor.

Vê-se que os dois modelos têm previsões ótimas 1 passo à frente e desempenhos similares para a simulação livre. Os erros de predição são exibidos na Figura 31, na qual se nota um comportamento próximo ao normal dos erros para todos os horizontes de predição.

Figura 31 - Erros de predição.

Fonte: Autor.

As Figura 32 e 33 apresentam o comportamento do índice *fit* dos modelos para diversos passos à frente.

Figura 32 - *Spider plot* dos índices *fit* para diversos horizontes de predição.

Fonte: Autor.

Figura 33 - Y2 - Distribuição dos índices $\hat{fit}$ para diversos horizontes de predição.

Fonte: Autor.

A Figura 33 indica que a capacidade de predição dos modelos decai com o horizonte de predição. Nota-se que o modelo de perturbação tem efeito até o horizonte de predição de 20 minutos e as predições se comportam praticamente como simulação livre para horizontes maiores.

4.6.2 VALIDAÇÃO DE THEIL DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

A validação de Theil avalia a capacidade de predição dos modelos, sendo um complemento ao índice fit. A Figura 34 mostra a distribuição dos índices de Theil para diversos horizontes de predição. É pertinente pontuar que através da validação de Theil é possível notar uma pequena diferença de comportamento entre os modelos, sendo que o modelo ARMAX é melhor.

Figura 34 -Y2 - Distribuição de índices de Theil para diversos horizontes de predição.

Fonte: Autor.

4.6.3 ANÁLISE DE RESÍDUOS DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

Esta análise observa os resíduos de predição do modelo. São feitas uma análise de correlação, uma modelagem de resposta ao impulso e uma análise em frequência dos resíduos, vistas na Figura 35.

Figura 35 - Y-2 - Análise de correlação dos resíduos.

Fonte: Autor.

Nota-se na análise de correlação da Figura 35 que os resíduos ficam dentro das regiões de confiabilidade em praticamente todos os valores de atraso para todos os modelos, validando ambos os modelos.

Figura 36 - Y2- Resposta ao impulso dos resíduos.

Fonte: Autor.

Na resposta ao impulso dos resíduos da Figura 36, os modelos têm resultados similares.

Figura 37 - Y2- Resposta em frequência dos resíduos.

Fonte: Autor.

Nota-se na Figura 37 resultados muito similares para ambos os modelos e que os erros são maiores em frequências mais altas, o que se deve aos sinais de onda quadrada usados.

4.6.4 ANÁLISE DOS GANHOS ESTACIONÁRIOS DOS MODELOS DA Y-2 PIC-23039

A Figura 38 exibe os ganhos dos modelos selecionados, assim como suas médias e desvios padrão. Observa-se que os dois modelos apresentam ganhos similares.

Figura 38 -Y2- Ganhos estacionários.

Fonte: Autor.

4.6.5 VALIDAÇÃO *ERROR BOUND* DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

A validação *Error Bound* (vide Figura 39) faz uma análise em frequência da incerteza do modelo, classificando a qualidade do modelo por bandas de frequência. Observa-se uma alta incerteza no domínio da frequência para os modelos identificados. Isto se deve ao tipo de sinal de excitação empregado, uma vez que a onda quadrada não excita adequadamente as dinâmicas da planta. Este resultado é esperado em pré-identificações com onda quadrada.

Figura 39 -Y2- Validação *Error Bound*.

Fonte: Autor.

4.6.6 MAPA DE POLOS E ZEROS DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

O mapa de polos e zeros dos modelos identificados é mostrado na Figura 40.

Figura 40 - Y2- Mapa de polos e zeros.

Fonte: Autor.

4.6.7 RESPOSTA EM FREQUÊNCIA DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

A Figura 41 mostra a resposta em frequência dos modelos identificados.

Figura 41 -Y2- Resposta em frequência dos modelos identificados.

Fonte: Autor.

4.6.8 RESPOSTA AO DEGRAU DOS MODELOS DA VARIÁVEL Y-2 PIC-23039

A Figura 42 exibe a resposta a degrau dos modelos identificados e a resposta a degrau dos modelos de perturbação. Indicam-se também os tempos de acomodação de cada modelo.

Figura 42 -Y2 – Resposta ao degrau dos modelos de processo identificados.

Fonte: Autor.

No gráfico da Figura 42, se observa o ganho negativo na resposta da FIC-23003 (perturbação medida). Esta resposta reflete com precisão o comportamento do processo, isto é, quando se aplica o degrau no *set-point* (positivo ou negativo) da variável controlada PIC-23039 (pressão de gás combustível), ocorre um aumento ou diminuição na pressão de gás combustível.

Dependendo da intensidade desta perturbação (incremento ou decremento do *set-point*), a mesma produzirá um incremento ou diminuição na disponibilidade de gás para o sistema de combustão do forno, ou seja, o sistema de geração de energia térmica (queimadores) irá variar a carga térmica para região de radiação de acordo com a disponibilidade dos combustíveis e comburente. As variações produzidas por esta perturbação (incremento ou decremento do sinal no *set-point*) irá impactar diretamente na produção do gás combustível e afetar diretamente a temperatura de saída do forno. A redução ou aumento da temperatura do gás de processo na saída do forno poderá ocasionar um aumento ou a diminuição na produção de gás de processo no reator xisto.

Cabe frisar que, o efeito da resposta ao degrau da PIC-23039, considerados nos parágrafos anteriores, depende do sentido e intensidade da perturbação (degrau), ou seja, uma variação positiva ou negativa do *set-point* provocará um incremento ou decremento na produção de gás de processo.

4.7 PRÉ-IDENTIFICAÇÃO DO MODELO DA VARIÁVEL Y3 – AIC-23001

A terceira variável controlada identificada foi a concentração de O₂ para o controle de combustão do forno industrial, AIC-23001. O melhor modelo identificado tem estrutura BJ, sendo que os demais modelos foram rejeitados por apresentarem um desempenho não aceitável. Enfatiza-se que foram aceitos os modelos que apresentaram melhor resposta em relação a predição infinitos passos à frente.

$$\begin{array}{cccc}
 \text{FIC-23028} & \text{FIC-23025} & \text{FIC-23027} & \text{FIC-23003} \\
 \downarrow & \downarrow & \downarrow & \downarrow \\
 \left[\frac{-0.0006113 z^{-4}}{1 - 0.9457 z^{-1}} \quad \frac{4.584e^{-5} z^{-1}}{1 - 0.8693 z^{-1}} \quad \frac{-0.0003085 z^{-3} - 0.001098 z^{-5} + 0.001118 z^{-6}}{1 - 2.073 z^{-1} + 1.857 z^{-2} - 0.7569 z^{-3}} \quad \frac{0.006133 z^{-2}}{1 - 0.9951 z^{-1}} \right] \\
 \\
 \text{Perturbação não medida } \mathbf{H(z)} = \frac{0.01773 - 0.003084 z^{-1} - 0.01219 z^{-2}}{1 - 2.076 z^{-1} + 1.598 z^{-2} - 0.6088 z^{-3} + 0.09415 z^{-4}}
 \end{array}$$

4.7.1 VALIDAÇÃO FIT DO MODELO DA VARIÁVEL Y3 – AIC-23001

A Figura 43 apresenta as predições do modelo para 1 passo à frente e a Figura 44 apresenta as predições infinito passos à frente do modelo.

Figura 43 - Y3 – Predições 1 passo à frente.

Fonte: Autor.

Figura 44 - Y3- Simulação livre.

Fonte: Autor.

Observa-se que o modelo tem boa capacidade de predição 1 passo à frente e na simulação livre. Durante os testes, observou-se uma variabilidade na malha, com oscilações contínuas, as quais não foram modeladas. Esta malha foi verificada antes dos testes e não foi detectado nenhum problema de sintonia no controlador PID, sensores ou atuadores. Após o teste de pré-identificação foi solicitada uma nova verificação dos elementos da malha de controle.

Os erros de predição observados são exibidos na Figura 45. Verifica-se um comportamento normal dos erros, para todos os horizontes de predição.

Figura 45 - Y3- Erros de predição.

Fonte: Autor.

As Figura 46 e 47 exibem o comportamento do índice *fit* para diversos passos à frente.

Figura 46 -Y3 -Spider plot dos índices *fit* para diversos horizontes de predição.

Fonte: Autor.

Figura 47- Y3 – Distribuição dos índices *fit* para diversos horizontes de predição.

Fonte: Autor.

Observa-se que a capacidade de predição dos modelos decai com o horizonte de predição. Nota-se ainda que o modelo de perturbação tem efeito apenas até o horizonte de predição de 5 minutos, posteriormente decaindo lentamente até o horizonte infinito.

4.7.2 VALIDAÇÃO DE THEIL DO MODELO DA VARIÁVEL Y3 – AIC-23001

A Figura 48 exibe os índices de Theil para diversos horizontes de predição.

Figura 48- Y3 – Distribuição dos índices de Theil para diversos horizontes de predição.

Fonte: Autor.

4.7.3 ANÁLISE DE RESÍDUOS DO MODELO DA VARIÁVEL Y3 – AIC-23001

A análise de correlação, a modelagem de resposta ao impulso e a análise em frequência dos resíduos dos modelos são exibidas nas Figura 49 e 50.

Figura 49- Y3 - Análise de correlação dos resíduos.

Fonte: Autor.

Observa-se na análise de correlação que os resíduos permanecem dentro das regiões de confiabilidade para todos os valores de atraso, validando-se o modelo.

Figura 50 - Y3 - Resposta ao impulso dos resíduos.

Fonte: Autor.

Na resposta ao impulso dos resíduos, novamente os valores permanecem dentro das regiões de confiabilidade, conforme mostrado na Figura 51.

Figura 51 - Y3 - Resposta em frequência dos resíduos.

Forte: Autor.

Nota-se na resposta em frequência dos resíduos que os erros são maiores em frequências mais altas, o que se deve à natureza dos sinais de onda quadrada usados na excitação da planta.

4.7.4 ANÁLISE DE GANHOS NO ESTADO ESTACIONÁRIO DO MODELO DA VARIÁVEL Y3 – AIC-23001

Os ganhos de estado estacionário obtidos para o modelo foram:

Resposta da AIC-23001 para as manipuladas: FIC-23028.SP, FIC-23025.SP, FIC-23027.SP e FIC-23003, na ordem em que foram identificadas:

$$\checkmark \begin{bmatrix} -0.0113 & 0.0004 & -0.0106 & 1.2593 & . \end{bmatrix}$$

4.7.5 VALIDAÇÃO ATRAVÉS DO *ERROR BOUND* DO MODELO DA VARIÁVEL Y3 – AIC-23001

A Figura 52 exibe a validação *Error Bound* para o modelo identificado.

Figura 52 -Y3-Validação *Error Bound*.

Fonte: Autor.

Nota-se uma alta incerteza no domínio da frequência para o modelo identificado, o que se deve ao tipo de sinal de excitação usado, visto que a onda quadrada não excita adequadamente as dinâmicas da planta. Este resultado é esperado em pré-identificações com onda quadrada.

4.7.6 MAPA DE POLOS E ZEROS DO MODELO DA VARIÁVEL Y3 – AIC-23001

A Figura 53 exibe o mapa de polos e zeros do modelo identificado.

Figura 53 - Y3 - Mapa de polos e zeros.

Fonte: Autor.

4.7.7 RESPOSTA EM FREQUÊNCIA DO MODELO DA VARIÁVEL Y3 – AIC-23001

A Figura 54 mostra a resposta em frequência do modelo identificado.

Figura 54 - Y3 - Resposta em frequência do modelo identificado.

Fonte: Autor.

4.7.8 RESPOSTA AO DEGRAU DO MODELO DA VARIÁVEL Y3 – AIC-23001

A Figura 55 exibe a resposta ao degrau do modelo do processo e a Figura 56 exibe a resposta ao degrau do modelo de perturbação. São também indicados os tempos de acomodação de cada modelo.

Figura 55 - Y3 - Resposta ao degrau dos modelos de processo identificados.

Fonte: Autor.

Na Figura 55 se verifica que o ganho estático da AIC-23001 afeta a FIC-23003 (perturbação não medida). Uma alteração do *set-point* (sentido negativo) da AIC-23001 produz uma redução da vazão de ar (vazão de ar para combustão) e consequentemente elevação da temperatura da região de radiação e convecção, gerando um incremento na temperatura de saída do gás de processo do forno. Com o aumento da temperatura do gás de processo para a retorta (saída do forno), ocorre um aumento na produção de gás (FIC-23003). O efeito ocorre em ambos os sentidos (variação positiva ou negativa do *set-point*).

Figura 56- Y3 - Resposta ao degrau dos modelos de perturbação identificados.

Fonte: Autor.

Nota-se que a resposta ao degrau exibiu algumas oscilações, o que indica que pode haver algum problema com o sensor desta malha. O elemento primário (sensor) desta malha de controle é, um medidor tipo tubo de *Pitot*. Este tipo de medidor permite obter a velocidade do escoamento a partir da medição resultante entre duas pressões (dinâmica e estática).

As oscilações observadas na Figura 56 podem ser causadas por uma provável obstrução parcial em uma das tomadas internas do sensor, provocando o comportamento oscilatório do mensurando (vazão de ar). Esta poderá ser uma causa provável, uma vez que, durante a fase de planejamento do experimento a equipe de manutenção efetuou as verificações e calibrações desta malha, e não constatou nenhum problema no medidor.

Todavia, devido ao comportamento apresentado pela malha de controle de vazão de ar de combustão, foi recomendado a verificação e aferição do instrumento (sensor), incluindo a averiguação de uma possível obstrução parcial em um dos condutos (internos) do medidor.

4.8 MODELO MATEMÁTICO DO FORNO INDUSTRIAL DA PETROSIX®

Agregando-se todos os modelos identificados, foi obtido o modelo para o forno mostrado na próxima página. Este modelo foi validado para o ponto de operação exibido na Tabela 6.

Tabela 6 -Ponto de operação do modelo.

<i>Variável</i>	<i>Ponto de Operação</i>
Variáveis Controladas	
Y1 – TIC 23099	557
Y2 – PIC 23039	5.1
Y3 – AIC 23001	3.14
Variáveis Manipuladas	
U1 – FIC 23028.SP	2412
U2 – FIC 23025.SP	52686
U3 – FIC 23027.SP	688
Perturbação Medida	
FIC 23003	160

Fonte: Autor.

O modelo identificado é representativo do forno industrial em torno do ponto de operação e para baixas frequências, em razão dos testes de validação efetuados. Identificou-se um modelo de processo e um modelo de perturbações não medidas. O modelo final obtido é composto de estruturas ARX, ARMAX e BJ.

$$G(z) =$$

$$\left[\begin{array}{ccccc} \frac{0.002017 z^{-1}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} & \frac{-3.566e - 05 z^{-6}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} & \frac{0.001671 z^{-2}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} & \cdot & \frac{-0.04359 z^{-1}}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} \\ \frac{4.716e^{-6} z^{-1}}{1 - 2.69 z^{-1} + 2.42 z^{-2} - 0.73 z^{-3}} & \frac{-8.23e^{-7} z^{-47} + 1.08e^{-6} z^{-48} - 2.95e^{-7} z^{-49}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}} & \frac{-0.0003 z^{-3} - 0.0011 z^{-5} + 0.0011 z^{-6}}{1 - 2.073 z^{-1} + 1.857 z^{-2} - 0.757 z^{-3}} & \frac{0.0006535 z^{-6}}{1 - 2.69 z^{-1} + 2.42 z^{-2} - 0.73 z^{-3}} & \frac{0.0003 z^{-4} - 0.0023 z^{-5} + 0.0036 z^{-6} - 0.0021 z^{-7}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}} \\ \frac{-0.0006113 z^{-4}}{1 - 0.9457 z^{-1}} & \frac{4.584e^{-5} z^{-1}}{1 - 0.8693 z^{-1}} & \frac{-0.0003 z^{-3} - 0.0011 z^{-5} + 0.0011 z^{-6}}{1 - 2.073 z^{-1} + 1.857 z^{-2} - 0.757 z^{-3}} & \frac{-0.213 z^{-2}}{1 - 1.031 z^{-1} + 0.8454 z^{-2}} & \frac{0.006133 z^{-2}}{1 - 0.9951 z^{-1}} \end{array} \right]$$

$$H(z) = \left[\begin{array}{c} \frac{0.002991}{1 - 1.723 z^{-1} + 0.7384 z^{-2}} \\ \frac{0.002951 - 0.002226 z^{-1}}{1 - 2.689 z^{-1} + 2.423 z^{-2} - 0.7321 z^{-3}} \\ \frac{0.01773 - 0.003084 z^{-1} - 0.01219 z^{-2}}{1 - 2.076 z^{-1} + 1.598 z^{-2} - 0.6088 z^{-3} + 0.09415 z^{-4}} \end{array} \right]$$

CAPÍTULO 5

IDENTIFICAÇÃO DOS MODELOS COM SINAIS *PRBS*

Neste capítulo são mostrados os resultados do processo de identificação do forno industrial, com o emprego de sinais de excitação *PRBS* (*Pseudo-Random Binary Sequence* ou sequência binária pseudo-aleatória). O planejamento do experimento foi elaborado a partir dos dados obtidos na pré-identificação, através do método degrau. Faz parte deste capítulo a descrição detalhada da preparação do experimento até a obtenção do modelo final em espaço de estados. Não obstante, cabe destacar que, foi criado um modelo matemático do forno industrial da SIX através da coleta e tratamento de dados das variáveis de processo de interesse e posterior identificação, usando a estrutura ARMAX (LJUNG, 1999).

5.1 MOTIVAÇÃO PARA UTILIZAÇÃO DO SINAL *PRBS*

Os sinais de teste tipo degrau promovem a excitação, principalmente, das características estacionárias do sistema, ou seja, excita com maior potência as regiões de baixas frequências. Este método é o mais utilizado na indústria de petróleo e petroquímica. Por outro lado, a medida que aumenta a frequência a potência da excitação é reduzida. Este sinal de excitação ou perturbação tipo degrau tem como característica permanecer em períodos específicos em um determinado valor de amplitude. O método tipo degrau (*step-test*) é utilizado com grande recorrência na identificação de modelos matemáticos de plantas industriais, em razão da sua simplicidade e facilidade de implementação, ou seja, são sinais realizáveis não requerendo formulações matemáticas complexas para definição e reprodução da excitação. Todavia a utilização desta técnica não é recomendada para sistemas multivariáveis (MIMO). Este método mostra-se adequado para plantas e sistemas SISO (Single Input Single Output), onde a identificação pode ser realizada através da perturbação individual de cada variável do processo, observando o seu efeito nas saídas. O uso da resposta ao degrau é apropriada para identificação de sistemas que operam em baixa frequência e que trabalhem muito próximos à região nominal de operação (região linear) (ISERMANN; MÜNCHHOF, 2011), (LJUNG, 1999). Em termos práticos a identificação com sinais de testes tipo degrau são aplicados de maneira independente, ou melhor, os sinais de excitação são gerados para cada variável manipulada. Contudo, este método não é recomendado para plantas ou processos, com forte acoplamento, pois

sistemas fortemente acoplados tendem a deslocar a faixa nominal de operação da planta. No entanto, o método de identificação através de sinais de excitação tipo *PRBS*, são empregados devido à sua capacidade de excitar simultaneamente um conjunto de variáveis, diminuindo o período de testes. Outra vantagem do método *PRBS* é a capacidade de excitar o processo em uma larga faixa de frequências. Entretanto, este método requer a priori uma etapa de cálculo para definição dos tempos dos sinais excitação (sinais binários aleatórios), além do conhecimento prévio da constante de tempo do processo.

O sinal *PRBS* mostra-se adequado em relação ao método de excitação do tipo degrau, o qual é recomendável apenas para a geração de pré-modelos, ou melhor, em razão da excitação degrau ser persistente excitante apenas de ordem 1 (ZHU, 2001). O período de permanência do sinal de excitação do sinal *PRBS* para cada nível lógico (alto e baixo) denota um limite mínimo e um limite máximo, sendo que estes limites são obtidos através das equações [11 a 18], disponíveis na Seção 5.2. As características do método de identificação *PRBS* (capacidade de excitar uma larga faixa de frequência), propicia a obtenção de um conjunto de dados com maior volume de informações, ou seja, as informações contidas no sinal de resposta da planta traduz com maior precisão o comportamento dinâmico do processo (LJUNG, 1999). Não obstante, é importante ressaltar que, o método *PRBS* é adequado para alguns cenários industriais, onde a presença de distúrbios não medidos (ruído de processo), os quais são componentes estocásticos que precisam ser caracterizados e contemplados pelos modelos, assim como a distribuição estatística do ruído de medida (ruído do sensor).

Na identificação procura-se obter modelos que retratem e contemplem os efeitos estocásticos das perturbações não medidas. A pré-identificação teve como principal interesse a obtenção da relação entre a entrada e a saída (modelo determinístico) e distúrbios não medidos, por esta razão foi empregado o método do tipo degrau. Convém complementar que, cada tipo de método de identificação, apresenta particularidades adequadas para um determinado propósito (características do processo e problema que se quer solucionar), e excita o sistema de maneira diferente, sendo capaz de disponibilizar diferentes modelos, de acordo com a riqueza dos dados obtidos a partir da resposta do sistema frente a cada perturbação (excitação). Na Tabela 7 é mostrada a comparação entre os sinais tipo degrau e *PRBS*.

Outro aspecto importante relacionado a com o processo de identificação do forno industrial é que, os testes com sinais *PRBS*, foram realizados em malha fechada. A identificação em malha fechada produz um conjunto de dados que permitem estimar modelos com maior precisão em relação ao sistema real (GEVERS, 2003) (ISERMANN; MÜNCHHOF, 2011).

Tabela 7- Comparação entre os sinais de excitação tipo degrau e *PRBS*.

Característica do Teste	Tipo de Sinais de Excitação Malha Aberta		Tipo de Sinais de Excitação Malha Fechada	
	Degradu	<i>PRBS</i>	Sinal Degrau	Sinal <i>PRBS</i>
Duração do Teste	Longo	Longo	Longo	Curto
Facilidade de Execução	Simples	Simples quando Automatizado, isto é, quando os sinais são gerados por blocos disponíveis na biblioteca do Sistemas Digitais de Controle Distribuido.	Simples	Simples
Deslocamento da faixa de operação da planta	Alto	Médio	Baixo	Baixo
Cálculo das Amplitudes dos Sinais de Excitação	Heurístico	Heurístico	Heurístico	Heurístico
Sensibilidade a Distúrbios Não Medidos	Médio	Intermediário	Médio	Alto - controlador correlaciona entrada e saída
Sensibilidade a Ruídos de Medição	Baixa	Baixa	Baixa	Baixa
Frequência Excitadas	Baixas	Toda ou grande parte do espectro de frequência.	Médio -Depende da Sintonia do Controlador PID	Grande parte da faixa de frequência. Depende da Sintonia do Controlador PID
Uso Sistema MIMO	Utilizado	Raramente	Pouco explorado	Utilizado

Fonte: Adaptado (MACHADO, 2004).

5.2 PREPARAÇÃO DO EXPERIMENTO

O sinal *PRBS* é uma sequência binária que, apesar de ser gerada a partir de um algoritmo determinístico, exibe comportamento estatístico similar a uma sequência aleatória. O sinal *PRBS* assume apenas dois valores (nível alto e baixo) e permanece períodos distintos em cada valor, aleatoriamente. Uma das características do sinal *PRBS* é a sua capacidade de excitar uma ampla faixa de frequências. Para isto, deve ser calculado o período mínimo em que o sinal deve ficar em um determinado valor, conhecido como tempo de bit.

Uma sequência binária é definida como uma sequência $a_0, \dots, a_{N-1}$ de N bits tal que:

$$a_j \in \{0,1\} \text{ para } j = 0,1, \dots, N-1 \quad (11)$$

Uma sequência consiste de $m = \sum a_j$ uns e $N - m$ zeros e de uma função de autocorrelação dada por:

$$C(v) = \sum_{j=0}^{N-1} a_j a_{j+v} \quad (12)$$

com somente dois valores:

$$C(v) = \begin{cases} m, & \text{se } v \equiv 0 \pmod{N} \\ mc, & \text{caso contrário} \end{cases} \quad (13)$$

onde:

$$c = \frac{m-1}{N-1} \quad (14)$$

conhecido como ciclo de trabalho.

Um conjunto possível de critérios para definir os sinais *PRBS* é o seguinte:

$$T \geq 2 \cdot N_u \cdot T_{ss} \quad (15)$$

$$\frac{1}{10} \cdot T_{sw} \leq \tau_{dom}^H \leq T_{sw} \quad (16)$$

$$T_{sw} \leq \frac{2,78 \cdot \tau_{dom}^L}{\alpha_s} \quad (17)$$

$$N_s = 2^n - 1 \geq \frac{2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H}{T_{sw}} \quad (18)$$

onde:

T	– Tempo total do experimento
T_{ss}	– Tempo de estabilização
N_u	– Número de entradas
T_{sw}	– Tempo entre possíveis chaveamentos

τ_{dom}^L	– Constante de tempo dominante, estimativa mínima
τ_{dom}^H	– Constante de tempo dominante, estimativa máxima
α_s	– Razão de resposta entre malha aberta e fechada
β_s	– Fator de tempo de estabilização
n	– Ordem do <i>PRBS</i>
N_s	– Número de chaveamentos do <i>PRBS</i>

O tempo de chaveamento é o período que deve ser respeitado para que as variáveis coletadas tenham tempo para atingir seus novos patamares de estado estacionário. Este conjunto de critérios é uma compilação de recomendações que pode ser encontrada em (FARLANE; RIVERA, 1992), (RIVERA; FLORES, 2000), (ZHU; BUTOYI, 2002), (KLERK; GRAIG, 2003). Para a realização do experimento foram usados os parâmetros da Tabela 8. O sistema de integração de dados do SDCD (Sistema Digital de Controle Distribuído) da planta e apresentação de valores, conhecido como PI (*Plant Information System*) foi usado para a coleta e gravação dos dados em planilhas Microsoft Excel (SILVEIRA *et al.*, 2012). O intervalo de amostragem, T_r , foi definido como 1 s.

Tabela 8. Parâmetros de planejamento para a excitação da planta com sinais *PRBS*.

Parâmetro	Valor	Unidade de Medida
T_{ss}	80	minutos
N_u	3	unidades
T_{sw}	35	minutos
τ_{dom}^L	40	minutos
τ_{dom}^H	80	minutos
α_s	2	adimensional
β_s	2	adimensional
n	5	adimensional
T_r	1	segundos
T	1120	minutos

Fonte: Autor.

A Tabela 9 apresenta as variáveis coletadas no experimento. A ordem das variáveis de saída para a identificação é TIC-23099, AIC-23001 e PIC-23039 e a ordem das variáveis de entrada é FIC-23027.SP, FIC-23028.SP, FIC-23025.SP e FIC-23003. SP.

Tabela 9. Variáveis coletadas no experimento.

Variável de processo	Tipo
FIC-23027.SP	Entrada
FIC-23028.SP	Entrada
FIC-23025.SP	Entrada
TIC-23099	Saída
AIC-23001	Saída
PIC-23039	Saída
FIC-23003	Perturbação de entrada medida

Fonte: Autor.

A Tabela 10 apresenta os tempos mínimos definidos para a coleta das variáveis de saída entre chaveamentos, levando em conta seus tempos de acomodação.

Tabela 10. Tempos de chaveamento para respeitar os tempos de acomodação.

Variável de Processo	T_p – Constante de tempo (min)	T_d – Tempo morto (min)	T_s – Tempo de acomodação (min)
TIC-23099	18	6	80
PIC-23039	2	0	10
AIC-23001	18	5	18

Fonte: Autor.

Esses tempos foram estimados através da avaliação dos dados históricos da unidade e de entrevistas com operadores do processo.

5.3 REALIZAÇÃO DO EXPERIMENTO

O tempo total de coleta de dados deveria ser de 18 horas e 40 minutos, porém após um pouco mais de 8 horas de coleta de dados, a unidade se tornou instável por razões alheias à aplicação dos sinais de identificação, demandando que os operadores retomassem o controle manual da planta para fazê-la retornar a uma condição segura. Do total planejado de 67.200 amostras das 7 variáveis de interesse, foram efetivamente coletadas 32.400, porém, de acordo com (ROFFEL; BETLEM, 2004), são necessárias $4,5 \cdot N_u \cdot T_s \cdot 2$, ou 3.600 amostras para se realizar uma identificação com *PRBS*. Neste experimento, 32.400 amostras foram obtidas, uma quantidade 9 vezes maior que a mínima. O autor considera então que o número de amostras respeita e ultrapassa com folga a proposta heurística e pode ser aceita sem prejuízo da identificação.

Por outro lado, para que as restrições das Equações (15), (16), (17) e (18) fossem respeitadas, os valores apresentados na Tabela 11 foram usados. As constantes são $n = 5$, $N_u = 3$, $T_s = 80$ m, $\tau_{dom}^L = 40$, $\tau_{dom}^H = 80$ m, $\alpha_s = 2$ e $\beta_s = 2$.

Tabela 11. Conformidade às restrições de aplicação do *PRBS*.

Restrição	Valores numéricos	Valor planejado	U.M.
Equação (5)	$T \geq 480$	1120	m
Equações (6) e (7)	$8 \leq T_{sw} \leq 80$ e $T_{sw} \leq 55,6$	35	m
Equação (8)	$N_s \geq 29$	31	adim

Fonte: Autor.

Por conta da parada prematura na coleta dos dados, T acabou ficando como 540 minutos. A restrição da Equação (18) continuou a ser respeitada, mesmo com a parada prematura.

5.4 DADOS BRUTOS COLETADOS

O experimento gerou 226.800 valores individuais distribuídos entre as 7 variáveis de interesse por 32.400 s. São apresentados nas Figura 57 a 63 os valores brutos coletados. A Figura 57 apresenta as 32.400 amostras coletadas para a variável controlada de temperatura TIC-23099.

Figura 57 . Dados da variável de processo TIC-23099.

Fonte: Autor.

A Figura 58 apresenta as amostras coletadas para o percentual de oxigênio AIC-23001.

Figura 58. Dados da variável de processo AIC-23001.

Fonte: Autor.

A Figura 59 mostra as amostras da pressão de gás combustível (PIC-23039).

Figura 59. Dados da variável de processo PIC-23039.

Fonte: Autor.

A Figura 60 exibe a primeira variável manipulada, a pressão FIC-23027.SP (*set-point*).

Figura 60. Dados do *set-point* da FIC-23027.

Fonte: Autor.

A Figura 61 apresenta a segunda variável manipulada, a vazão de óleo combustível (FIC-23028.SP) (*set-point*).

Figura 61 . Dados do *set-point* da FIC-23028.

Fonte: Autor.

A Figura 62 exibe a terceira variável manipulada, a vazão FIC-23025.SP (*set-point*).

Figura 62. Dados do *set-point* da FIC-23025.

Fonte: Autor.

A Figura 63 exibe a perturbação medida FIC-23003 - vazão do gás de processo.

Figura 63. Dados do *set-point* da vazão de gás de processo (FIC-23003), uma perturbação medida.

Fonte: Autor.

5.5 TRATAMENTO DOS DADOS

O processo de identificação demanda uma análise dos dados brutos coletados, visando:

1. Facilitar o processo de identificação;
2. Remover sinais espúrios;
3. Mudar a frequência de amostragem, se necessário;
4. Filtrar frequências altas, no caso dos dados coletados neste trabalho.

Para a identificação do forno, as fases de normalização, reamostragem e remoção de *outliers* foram realizadas. A filtragem não foi necessária, pois o processo de reamostragem já a realiza, através da interpolação dos dados.

5.5.1 NORMALIZAÇÃO

A normalização dos dados coletados visa tornar mais fácil o processo de identificação, na medida em que traz as variáveis para a mesma escala, evitando distorções devidas às diferenças entre os diferentes intervalos das variáveis. Os dados normalizados ficaram na faixa $[0, 1]$.

As variáveis controladas normalizadas são apresentadas na Figura 64.

Figura 64 - Dados normalizados das variáveis controladas.

Fonte: Autor.

As variáveis manipuladas normalizadas são apresentadas na Figura 65.

Figura 65 - Dados normalizados das variáveis manipuladas.

Fonte: Autor.

5.5.2 REAMOSTRAGEM

Após a normalização foi feita uma reamostragem dos dados, usando a função *Resample* do *Signal Processing Toolbox* do MATLAB. O motivo para a reamostragem é que os controladores usados no forno têm frequência de 1/60 Hz. Além disso, uma menor quantidade de pontos acelera o processo de identificação no MATLAB. Os 32.400 pontos coletados para cada variável segundo a segundo se transformaram em 540 pontos reamostrados minuto a minuto.

O MATLAB aplica um filtro FIR (*Finite Impulse Response*) passa-baixas para antisserrilhamento nas amostras e compensa os atrasos inseridos por esse filtro (MATHWORKS, 2019). Os argumentos para o comando *resample* são os dados de entrada e de saída e a razão de reamostragem. Por padrão, o filtro para antisserrilhamento possui a ordem definida na Equação (19):

$$f_{order} = 2 \cdot n \cdot \max(p, q) \quad (19)$$

onde f_{order} é a ordem do filtro a ser aplicado, n é um fator adimensional sendo o valor padrão $n = 1$ e p e q definem a razão da nova taxa de amostragem, no caso $p = 1$ e $q = 60$.

A Figura 66 apresenta os dados reamostrados para as variáveis controladas e a Figura 67 apresenta os dados reamostrados para as variáveis manipuladas.

Figura 66 - Dados reamostrados das variáveis controladas.

Fonte: Autor.

Figura 67 - Dados reamostrados das variáveis manipuladas.

Fonte: Autor.

5.5.3 REMOÇÃO DE *OUTLIERS*

A última fase do tratamento dos dados foi a remoção dos *outliers*. A definição usada neste trabalho é que um *outlier* é um elemento que é maior que o desvio mediano absoluto (DMA) a partir da mediana. A DMA normalizada é definida como:

$$K \cdot \text{mediana}(\text{abs}(A - \text{mediana}(A))) \quad (20)$$

onde K , o fator de escala, é aproximadamente 1,4826 (MATLAB, 2019).

As leituras consideradas como *outliers* foram interpoladas na última fase, pois a remoção logo após a coleta dos valores brutos levou a cortes equivocados das medições, retirando leituras que claramente, por inspeção e análise junto à operação, não eram *outliers*. A Figura 68 mostra um exemplo de interpolação de uma amostra tida como um *outlier* correto na AIC-23001.

Figura 68 - Zoom de uma interpolação realizada pelo comando *filloutliers*.

Fonte: Autor.

5.5.4 MATRIZ DE CORRELAÇÃO

Para análise e verificação da hipótese de nenhuma correlação entre as variáveis manipuladas e controladas, um coeficiente estatístico definido como p-valor, apresenta a probabilidade de se obter uma correlação tão forte quanto um valor observado aleatoriamente, quando a correlação verdadeira é zero. Se p-valor for menor que 0,05, ou 5%, então a correlação é significativa. A Tabela 12 apresenta os p-valores entre as variáveis manipuladas e as controladas após o tratamento realizado nelas. Os coeficientes sem correlação significativa estão sublinhados.

Tabela 12. Teste da hipótese de nenhuma correlação – p-valores.

Variável	FIC-23027.SP	FIC-23028.SP	FIC-23025.SP	FIC-23003
TIC-23099	<u>0,2301</u>	0	0,0170	0
AIC-23001	0	0	0	0
PIC-23039	<u>0,4474</u>	<u>0,4355</u>	0	<u>0,2157</u>

Fonte: Autor.

O autor realizou uma identificação multivariável e preferiu manter as identificações individuais sem alteração, mesmo com quatro correlações sem significância estatística entre elas.

5.6 IDENTIFICAÇÃO DO MODELO

Após o tratamento dos dados, a próxima fase foi a identificação da planta. O autor usou recursos do pacote Identification Toolbox do MATLAB para realizar essa tarefa. Nesse pacote estão disponíveis várias funções de identificação e para esse trabalho a função *armax*, que estima os parâmetros de um modelo ARMAX (LJUNG, 1999) foi mais uma vez escolhida. O modelo ARMAX possui uma estrutura que inclui a dinâmica estocástica, modelando perturbações na entrada, a serem usadas para gerar um modelo do forno que inclua a perturbação de entrada não medida, oriunda dos resíduos dessa identificação.

A identificação feita foi validada para os valores nominais de operação da Tabela 13.

Tabela 13. Valores nominais das variáveis usadas para a identificação.

Variável de processo	Tipo	Valor nominal
FIC-23027.SP	Entrada	1367,28
FIC-23028.SP	Entrada	2171,89
FIC-23025.SP	Entrada	55861,20

FIC-23003	Perturbação medida de entrada	147,24
TIC-23099	Saída	567,97
AIC-23001	Saída	1,42
PIC-23039	Saída	4,89

Fonte: Autor.

A função *armax* aceita como parâmetros os dados de entrada e saída e a ordem da identificação. Uma identificação de segunda ordem foi realizada, com os parâmetros mostrados na Tabela 14.

Tabela 14. Parâmetros usados na identificação com estrutura ARMAX.

Parâmetro	Valor
Na	$\begin{bmatrix} 2 & 2 & 2 \\ 2 & 2 & 2 \\ 2 & 2 & 2 \end{bmatrix}$
Nb	$\begin{bmatrix} 2 & 2 & 2 & 2 \\ 2 & 2 & 2 & 2 \\ 2 & 2 & 2 & 2 \end{bmatrix}$
Nc	$\begin{bmatrix} 2 \\ 2 \\ 4 \end{bmatrix}$
Nk	$\begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 30 & 2 & 30 & 1 \end{bmatrix}$

Fonte: Autor.

5.6.1 IDENTIFICAÇÃO DA TIC-23099

A identificação ARMAX da TIC-23099 gerou o seguinte modelo, tendo como entrada as três manipuladas e a perturbação medida. Resposta da TIC-23099 para as manipuladas: FIC-23027.SP, FIC-23028.SP, FIC-23025.SP e FIC-23003, na ordem em que foram identificadas:

$$G_{TIC}(z) = \left[\begin{array}{c} 0.00098261 \cdot z^{-1} \cdot (1 - 0.8503 \cdot z^{-1}) (1 - 1.745 \cdot z^{-1} + 0.7635 \cdot z^{-2}) (1 + 0.5391 \cdot z^{-1} + 0.7362 \cdot z^{-2}) \\ (1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2}) \\ 0.0014262 \cdot z^{-1} (1 - 0.8492 \cdot z^{-1}) (1 + 0.7386 \cdot z^{-1}) (1 + 0.2711 \cdot z^{-1}) (1 - 1.819 \cdot z^{-1} + 0.8318 \cdot z^{-2}) \\ (1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2}) \\ 2.6895e - 5 \cdot z^{-1} (1 + 1.017 \cdot z^{-1}) (1 - 1.005 \cdot z^{-1}) (1 - 1.855 \cdot z^{-1}) (1 - 1.802 \cdot z^{-1} + 0.8128 \cdot z^{-2}) \\ (1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2}) \\ -0.0065372 \cdot z^{-1} (1 + 2.573 \cdot z^{-1}) (1 - 1.773 \cdot z^{-1} + 0.7859 \cdot z^{-2}) (1 - 0.7138 \cdot z^{-1} + 0.2403 \cdot z^{-2}) \\ (1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2}) \end{array} \right]^T$$

$$H_{TIC}(z) = \left[\frac{1 + 0.03615 \cdot z^{-1} + 0.2298 \cdot z^{-2}}{1 - 1.457 \cdot z^{-1} + 0.5116 \cdot z^{-2}} \right]$$

A Figura 69 exibe o resultado da validação da TIC-23099 para infinitos passos à frente.

Figura 69. Comparação entre modelo identificado e dados coletados para predição infinitos passos à frente da TIC-23099.

Fonte: Autor.

5.6.2 IDENTIFICAÇÃO DA AIC-23001

A identificação ARMAX da AIC-23001 gerou o seguinte modelo, tendo como entrada as três variáveis manipuladas:

Resposta da AIC-230001 para as manipuladas: FIC-23027.SP, FIC-23028.SP, FIC-23025.SP e FIC-23003, na ordem em que foram identificadas:

$$G_{AIC}(z) = \begin{bmatrix} \frac{-0.00026038 \cdot z^{-1} (1 + 2.246 \cdot z^{-1}) (1 - 0.9384 \cdot z^{-1}) (1 - 0.6251 \cdot z^{-1}) (1 - 1.742 \cdot z^{-1} + 0.7611 \cdot z^{-2})}{(1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})} \\ \frac{-0.00080281 \cdot z^{-1} (1 + 0.2565 \cdot z^{-1}) (1 - 0.5851 \cdot z^{-1}) (1 - 0.9379 \cdot z^{-1}) (1 - 1.834 \cdot z^{-1} + 0.8461 \cdot z^{-2})}{(1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})} \\ \frac{-0.00037258 \cdot z^{-1} (1 + 9.461 \cdot z^{-1}) (1 - 0.926 \cdot z^{-1}) (1 + 0.1948 \cdot z^{-1}) (1 - 1.606 \cdot z^{-1} + 0.655 \cdot z^{-2})}{(1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})} \end{bmatrix}^T$$

$$H_{AIC}(z) = \left[\frac{1 - 0.03959 \cdot z^{-1} + 0.02499 \cdot z^{-2}}{1 - 1.457 \cdot z^{-1} + 0.5116 \cdot z^{-2}} \right]$$

A Figura 70 mostra o resultado da validação da AIC-23001 para infinitos passos à frente.

Figura 70. Comparação do modelo e dos dados coletados para predição infinitos passos à frente para a AIC-23001.

Fonte: Autor.

5.6.3 IDENTIFICAÇÃO DA PIC-23039

A identificação ARMAX da PIC-23039 gerou o seguinte modelo, tendo como entrada as três manipuladas e a perturbação medida.

Resposta da PIC-23039 para as manipuladas: FIC-23027.SP, FIC-23028.SP, FIC-23025.SP e FIC-23003, na ordem em que foram identificadas, de acordo com a matriz de ganhos da Tabela 15. Tabela 15 - Matriz de ganhos da variável PIC-23039.

Tabela 15 - Matriz de ganhos da variável PIC-23039.

TAG -230	$G_{PIC}(z) =$
FIC-027	$\frac{-0.0001766 \cdot z^{-1} (1 - 1.107 \cdot z^{-1}) (1 - 0.8881 \cdot z^{-1}) (1 + 0.1162 \cdot z^{-1}) (1 - 1.675 \cdot z^{-1} + 0.7405 \cdot z^{-2})}{(1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})}$
FIC-028	$\frac{(1 + 0.1941 \cdot z^{-1})}{(1 - 0.9416 \cdot z^{-1})(1 + 0.1642 \cdot z^{-1})(1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2})(1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})}$
FIC-025	$\frac{1.2692e - 6 \cdot z^{-1} (1 - 0.9312 \cdot z^{-1}) (1 - 0.8752 \cdot z^{-1}) (1 - 0.5342 \cdot z^{-1}) (1 - 0.3049 \cdot z^{-1} + 0.9172 \cdot z^{-2})}{(1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})}$
FIC-03	$\frac{-0.00037258 \cdot z^{-1} (1 + 9.461 \cdot z^{-1}) (1 - 0.926 \cdot z^{-1}) (1 + 0.1948 \cdot z^{-1}) (1 - 1.606 \cdot z^{-1} + 0.655 \cdot z^{-2})}{(1 - 0.9416 \cdot z^{-1}) (1 + 0.1642 \cdot z^{-1}) (1 - 1.78 \cdot z^{-1} + 0.7943 \cdot z^{-2}) (1 - 1.58 \cdot z^{-1} + 0.6433 \cdot z^{-2})}$
DV Distúrbio não medido	$H_{PIC}(z) = \left[\frac{1 - 0.141 \cdot z^{-1} + 0.2302 \cdot z^{-2} + 0.3245 \cdot z^{-3} + 0.04075 \cdot z^{-4}}{1 - 1.769 \cdot z^{-1} + 0.7923 \cdot z^{-2}} \right]$

Fonte: Autor.

A Figura 71 apresenta a predição dez passos à frente para a PIC-23039.

Figura 71. – Comparação do modelo e dos dados coletados para predição dez passos à frente para a PIC-23039.

Fonte: Autor.

5.6.4 RESULTADO COMPLETO DA IDENTIFICAÇÃO

A Figura 72 apresenta a resposta ao degrau dos modelos identificados. A resposta ao degrau, corresponde com precisão ao comportamento esperado do processo. Um degrau positivo na referência (*set-point*) da TIC-23099 produz como resultado imediato um aumento nas vazões de óleo e gás combustível (FIC-23027 e FIC-23028). Com o incremento nas vazões de combustíveis (óleo e gás), verifica-se uma redução do excesso de ar. A diminuição do excesso de ar (FIC-23025) é real, uma vez que a alteração da relação estequiométrica entre comburente (ar) e combustíveis (maior massa de combustíveis para uma mesma massa de ar de combustão). Este efeito aparece no gráfico da Figura 72 como uma resposta inversa.

Posterior ao efeito da redução do excesso de ar (O_2), observa-se o aumento da vazão de ar de combustão através da atuação da FIC-23025. Esta ação de controle é gerada em razão do desvio entre a variável de processo (excesso de ar) e seu *set-point* (FIC-23025). Outro efeito observado no gráfico da Figura 72 é a redução da vazão de gás de processo. Este resultado é em decorrência do aumento da massa de ar de combustão para a câmara de combustão, refletindo na diminuição da carga térmica para o gás de processo. Com a diminuição da carga térmica para o reator de xisto (retorta), ocorre uma diminuição na produção de gás de processo (resposta da FIC-23003).

Quando é aplicado um degrau negativo no *set-point* da AIC-23001, ocorre um aumento do excesso de ar de combustão, consonante com a diminuição das vazões de combustíveis, isto é, uma diminuição das vazões de óleo e gás combustível produz um desequilíbrio na relação estequiométrica comburente e combustível. Em decorrência da diminuição da vazão de ar para a câmara de combustão, observa-se um incremento na temperatura de saída do forno. O aumento da temperatura de saída do forno produz um aumento na produção de gás de processo na retorta.

O sinal degrau aplicado no *set-point* da PIC-23039 produz uma redução da vazão de óleo combustível (FIC-23028) e aumento da vazão de ar (FIC-23025). A diminuição da vazão de óleo combustível é em função do incremento da vazão de gás (maior poder calorífico), de modo a manter a estabilidade da temperatura do gás de processo na saída do forno (TIC-23099).

A atuação inversa entre a FIC-23027 (vazão de óleo) e a FIC-23028 (gás combustível) é causada pela diferença do poder calorífico do gás combustível (12132,5 Joule ou 11.000 BTU), isto é, o poder calorífico do óleo combustível é inferior ao do gás (7912,5 Joule 7500 BTU¹⁰). Em razão

¹⁰ O Joule é uma unidade padronizada pelo Sistema Internacional de Unidades (SI) para medição de energia. É definido que 1 caloria é igual a 4,1868 J (joules). A *British Thermal Unit* (BTU) apesar de não fazer parte do SI é uma unidade usada para expressar uma quantidade de calor. O BTU é muito usado para caracterização do trabalho de equipamentos e máquinas térmicas. 1 BTU equivale a 252,4 cal ou 1.055 J (ROZENBERG, 2006).

desta diferença, é necessário diminuir a vazão de óleo combustível para garantir a manutenção da temperatura de saída do gás de processo, de acordo com o *set-point* da TIC-23099.

Outro efeito observável é a resposta da FIC-23003 (vazão de gás de processo). Posterior ao incremento na vazão de ar de combustão (FIC-23025) ocorre um decremento na vazão de gás de processo. Este resultado é causado pelo acréscimo na vazão de ar para a combustão (FIC-23025). Este aumento da vazão de ar de combustão tem como consequência a diminuição da temperatura da parede dos tubos da região de radiação, acarretando a redução da taxa de troca térmica entre gás de processo e gases da combustão e, consequentemente, ocasionando a redução da temperatura do gás de processo (FIC-23003).

Figura 72. Resposta ao degrau unitário dos modelos identificados.

Fonte: Autor.

A matriz de ganhos para os três modelos identificados é apresentada na Tabela 16.

Tabela 16. Matriz de ganhos dos modelos identificados.

	FIC-23027.SP	FIC-23028.SP	FIC-23025.SP	FIC-23003
TIC-23099	0.0992	0.1087	-0.0005	-2.2717
AIC-23001	-0.0062	-0.0052	0.0003	0.0783
PIC-23039	0.0010	-0.0032	0.0001	-0.1615

Fonte: Autor.

As respostas em frequência da identificação *PRBS* não foram apresentadas porque todos os sinais são de baixa frequência e não houve diferenças significativas entre as variáveis identificadas utilizando excitação em degrau, com a exceção da PIC-388, que não foi identificada com o método

PRBS. Os valores constantes na Tabela 16 ficaram muito próximos do ganho estático das respostas ao degrau. O modelo final ficou:

$$G = [G_{TIC}; G_{PIC}; G_{AIC}]$$

5.6.5 REPOSTAS AO DEGRAU DOS MODELOS OBTIDOS

Analisou-se como o modelo representa a planta quando degraus são aplicados. Dois degraus de diminuição do valor de *set-point*, seguidos de outros dois degraus de aumento no valor de *set-point* foram aplicados. Os gráficos exibidos nas Figura 73 a 75 mostram as comparações, cujos valores estão normalizados entre 0 e 1 para propiciar uma melhor visualização.

Figura 73. Respostas a degraus aplicados na planta e no modelo identificado para a TIC-23099.

Fonte: Autor.

Figura 74. Respostas a degraus aplicados na planta e o modelo identificado para a AIC-23001.

Fonte: Autor.

Figura 75 - Respostas a degraus aplicados na planta e no modelo identificado para a TIC-23099.

Fonte: Autor.

A Figura 76 apresenta as auto-correlações dos resíduos e a correlação cruzada (XCorr) dos resíduos com os sinais de entrada. A função usada, *resid*, disponível no *System Identification Toolbox* do MATLAB, calcula os erros ou resíduos das predições. As correlações são geradas para a faixa de -25 a 25 atrasos. A banda em azul é a região de confiança de 99%, e as correlações estatisticamente insignificantes ficam dentro dessa faixa. A Figura 76 mostra que o modelo não apresenta relação entre os erros calculados e as entradas usadas e que os resíduos podem ser considerados como ruído branco, pois não há autocorrelação entre eles.

Figura 76 - Análise da autocorrelação dos resíduos e da correlação cruzada dos resíduos com as entradas.

Fonte: Autor.

5.7 ANÁLISE DA ESTABILIDADE DO MODELO IDENTIFICADO

Para que um sistema LTI em tempo discreto seja estável, é preciso que seus polos estejam dentro do círculo de raio unitário. Para verificar essa condição, os autovalores da matriz A de um modelo no espaço de estados podem ser usados. Um sistema discreto é dito estável se:

$$z_i = \sqrt{\text{Imag}(a_i) + \text{Real}(a_i)} < 1, 0 < i \leq n_x, i \in \mathbb{Z}^{*+} \quad (21)$$

onde n_x é o número de estados e a_i cada um dos autovalores de A .

Os valores absolutos dos autovalores do modelo identificado são apresentados na Tabela 17, confirmando que o modelo é estável.

Tabela 17 - Valores absolutos dos autovalores do modelo identificado.

I	Autovalor	Valor absoluto
1	$-0,1526 + 0,0000i$	0,1526
2	$0,7981 + 0,1261i$	0,8080
3	$0,7981 - 0,1261i$	0,8080
4	$0,9398 + 0,0000i$	0,9398
5	$0,9099 - 0,0000i$	0,9099
6	$0,8497 + 0,0000i$	0,8497

Fonte: Autor.

A Figura 77 apresenta os polos e zeros do modelo identificado.

Figura 77 - Mapa de polos e zeros do sistema identificado.

Fonte: Autor.

5.8 MODELO DE PERTURBAÇÃO NÃO MEDIDA

O modelo de perturbação não medida de entrada foi obtido através dos canais de ruído provenientes da identificação das variáveis de interesse do forno:

$$H = [H_{TIC}; H_{PIC}; H_{AIC}]$$

A estratégia para se obter esse modelo no MATLAB para posterior uso no controlador MPC a ser criado, proposta por Morari (2004), é através da geração de um modelo aumentado no espaço de estados, apresentado no Apêndice N. Não obstante, conforme destacado inicialmente neste capítulo, os modelos obtidos através da identificação com o sinal *PRBS* mostraram-se aderentes à dinâmica real da planta, uma vez que, através desta técnica conseguiu-se explicitar o modelo do processo e das perturbações não medidas.

Os experimentos da pré-identificação e identificação do processo (com sinais do tipo degrau e *PRBS*) foram realizados com o processo nas mesmas condições nominais de operação. No entanto, na identificação através do sinal degrau, não foi obtido um modelo (variância) representativo das perturbações não medidas (H). Pressupõe-se que esse resultado pode ser justificado pelo fato do sinal degrau não explorar toda a faixa operacional da planta (tipo de sinal não persistentemente excitante), não evidenciando assim todos os atributos estocásticos do processo (perturbações não medidas).

CAPÍTULO 6

IMPLEMENTAÇÃO E SINTONIA DO CONTROLADOR MPC

Este capítulo visa implantar os controladores M_{MPC} , usando o software MATLAB™ e a otimização de parâmetros (sintonia) através do algoritmo MOGA. Neste capítulo é descrita a preparação para os ensaios. Todavia, é importante frisar que se empregou nesta tese o termo M_{MPC} para denotar que se trata de um controlador implementado com recursos disponíveis na biblioteca *MPC Designer* do MATLAB™ 2019b.

6.1 IMPLEMENTAÇÃO DO CONTROLADOR MPC

A ferramenta MATLAB™ versão R2019b foi usada para criar o controlador MPC e para as simulações e análise de seu comportamento. Este software permite a instalação integrada de pacotes, que adicionam novas funcionalidades. Para implantar o controlador, otimizações, funções básicas de controle, criação de modelos visuais e processamento de sinais, foram usados os pacotes *Model Predictive Control Toolbox*, *Optimization Toolbox*, *Global Optimization Toolbox*, *Control Toolbox*, *Simulink* e *Signal Processing Toolbox* (MATHWORKS, 2019b). A estrutura do controlador MPC projetada neste software é mostrada na Figura 78.

Figura 78 - Estrutura dos modelos de planta, perturbações e ruído do MPC do MATLAB.

Fonte: Autor.

As variáveis de entrada e saída são apresentadas na Tabela 18.

Tabela 18 - Variáveis do MPC do MATLAB.

Variável	Terminologia MPC	Descrição
u	MV	Variável manipulada
y		Saídas da planta com ruídos de medição
yp		Saídas da planta
ym	MO	Saídas da planta medidas
yu	UO	Saídas da planta não medidas
r		Referências para <i>set-point</i>
v	MD	Perturbação de entrada medida
d	UD	Perturbação de entrada não medida
yod		Perturbações de saída
yn		Ruídos de medição
wid		Sinais de entrada para o modelo de perturbações de entrada não medidas
wod		Sinais de entrada para o modelo de perturbações de saída não medidas
wn		Sinais de entrada para o modelo de perturbações de saída não medidas

Fonte: Autor.

O M_{MPC} usa os três modelos gerados nas subseções 5.7 a 5.7.2 para realizar as previsões dos estados do controlador e estimar os estados da planta a ser controlada. Os estados do controlador são a junção dos estados desses três modelos, descritos a seguir neste capítulo.

A combinação desses três modelos gera o observador de estados, que é usado para estimar os valores dos estados não medidos necessários para as previsões e para prever como os ajustes nas variáveis manipuladas afetarão as saídas futuras da planta.

Se o modelo da planta não possuir perturbações de entrada não medidas, o M_{MPC} modela eventos desconhecidos usando um modelo de perturbação de saída, que funciona independentemente da planta e cuja saída é somada diretamente ao modelo da planta, caso contrário, se o modelo de d não for configurado, um integrador adimensional com ganho unitário é criado para cada perturbação de entrada não medida.

O modelo de ruído pode ser definido para que o ruído de medição seja ignorado, de forma contrária aos modelos de perturbação, que requerem uma resposta ativa do controlador.

6.1.1 MODELAGEM DO CONTROLADOR MPC

A implementação do MPC no MATLAB é relativamente genérica, pois o MATLAB permite a parametrização (sintonia) do controlador, estabelecimento de restrições, uso de variáveis de perturbação medidas e não medidas, definição dos horizontes de controle e de predição e muitos outros parâmetros (MATLAB, 2019b). Certas informações, porém, não estão imediatamente disponíveis, como por exemplo os estados internos do controlador. Além disso, os sinais para as variáveis de perturbação e de ruído devem ser especificados, caso contrário são considerados como ruído branco, com média zero e variância unitária. Todavia, caracteriza-se como um diferencial do MATLAB™ o fato de ele proporcionar ou permitir a utilização de perturbações não medidas, funcionalidade que não existe em uma série de soluções de mercado.

O M_{MPC} construído possui seus parâmetros iniciais apresentados na Tabela 19.

Tabela 19 – Parâmetros iniciais do MPC-MATLAB™.

Parâmetro	Sigla	Valor
Quantidade de saídas	n_y	3
Quantidade de entradas	n_u	3
Quantidade de perturbações medidas de entrada	n_{xid}	1
Quantidade de perturbações não medidas de entrada	n_d	3
Horizonte de controle	m	2
Horizonte de predição	p	40
Mínimos das manipuladas	MV_{min}	[418 492 34639]
Máximos das manipuladas	MV_{max}	[3056 2500 59326]
Mínimos das controladas	OV_{min}	[401.6 1 2.5]
Máximos das controladas	OV_{max}	[577 10 6]
Mínimos das taxas das manipuladas	$OV_{RateMin}$	[-Inf -Inf -Inf -Inf]
Máximos das taxas das manipuladas	$OV_{RateMax}$	[+Inf +Inf +Inf +Inf]
Ganhos de escala das manipuladas	S_i	[450 250 2000]
Ganhos de escala das controladas	S_o	[175.4 9 3.5]
Saídas nominal	Y_{nom}	[557 3.14 5.1]
Entrada nominal	U_{nom}	[1140 2412 52686 145]

Fonte: Adaptado (MATHWORKS, 2018).

O MPC como implementado no MATLAB realiza a remoção dos atrasos obtidos no modelo da planta antes de sua execução, através da inserção de estados nas matrizes A e C. A quantidade de estados adicionais é igual ao somatório dos atrasos identificados.

O modelo interno do MPC tem como entradas as variáveis de estado do controlador e as entradas ótimas calculadas e gera as saídas previstas, que são então utilizadas para a otimização. A Figura 79 apresenta a estrutura do modelo da planta interna ao MPC e seus sinais.

Figura 79 - Estrutura dos modelos de planta, perturbações e ruído do MPC do MATLAB.

Fonte: Autor.

6.1.2 PREDIÇÃO DOS ESTADOS DAS VARIÁVEIS ATRAVÉS DO FILTRO KALMAN

Controladores preditivos demandam a predição dos estados¹¹ futuros y_p , que é feita por um observador de estados, o qual, por sua vez, necessita de um filtro de Kalman (*Kalman Filter* - *KF*) (KALMAN, 1960). No artigo publicado por Rudolph E. Kalman em 1960, foi apresentada uma solução recursiva para o problema de filtragem linear de dados discretos. Trata-se de um algoritmo

¹¹ A representação em espaço de estados é um modelo matemático que representa um sistema físico (planta, processo, mecanismos, etc) composto por um conjunto de variáveis de entrada, saída e de estado, também conhecidas como variáveis de estado, correlacionadas através de equações diferenciais. Estas variáveis de estado são expressas através de vetores e as equações diferenciais e algébricas são escritas na forma matricial. Esta representação matemática é possível desde que o sistema dinâmico seja linear e invariante no tempo (SONTAG, 1998), (ENGELBERG, 2005).

matemático que pode ser usado para estimativa a partir de dados estocásticos, ou seja, medições ruidosas (WELCH; BISHOP, 2001).

Daqui por diante utiliza-se a abreviação *KF* para denominar o filtro de Kalman. O algoritmo do *KF* é capaz de estimar variáveis de estados a partir do modelo da planta, modelo do ruído de medição e modelo do ruído de processo. Estes modelos são utilizados para o cálculo e estimação de variáveis futuras com base em valores atuais (medições). Toda a fundamentação teórica do *KF* é estabelecida considerando a existência de ruídos de processo e de medição. Inicialmente, o *KF* foi proposto para sistemas lineares e discretos, mas desde então foram desenvolvidas novas versões deste filtro, incluindo sistemas contínuos (WELCH; BISHOP, 2001)

O *KF* é baseado em ferramentas estatísticas como: variância, covariância, média, distribuição de probabilidade gaussiana, equações recursivas para predição e atualização de estados, estimador em forma de espaço de estados e medição da saída do processo. A combinação destas ferramentas estatísticas permite a estimação dos estados de um sistema ou processo.

Na Figura 80 é mostrada a topologia interna do filtro de Kalman (*KF*). O processo de estimação dos estados no *KF* retorna valores menos afetados pelo ruídos ($\mathbf{y}_v$) e, consequentemente, a grandeza estimada ($\mathbf{y}_e$) estará mais próxima ao valor verdadeiro ($\mathbf{u}$). Um dos grandes aperfeiçoamentos do *KF* é a técnica de filtragem de ruídos, que são diferenciados em ruídos de processo (presentes na planta) e de medição (inerentes ao sensor usado) (KIM; BANG, 2019). Na grande maioria das plantas industriais observa-se a ocorrência de ruídos, provenientes do processo e da medição (sensores). Conforme destacado no início deste parágrafo, em razão da existência destas fontes de ruído ($\mathbf{y}_v$), o *KF* disponibiliza na sua saída um sinal ($\mathbf{y}_e$) filtrado, isento do ruído de processo e do ruído de medição, ou seja, com menor efeito de interferência de ruído em relação ao estado calculado apenas pelo estimador (KIM; BANG, 2019).

Figura 80 - Topologia básica do filtro de Kalman.

Fonte: Autor.

Desde o surgimento do *KF*, novas topologias foram sendo criadas e incorporadas, visando resolver problemas de sistemas não lineares, com o objetivo de melhorar a eficiência da predição do filtro (MOHINDER; ANGUS, 2008). Dentre essas topologias, destaca-se a versão estendida do Filtro de Kalman, conhecido como *EKF* (*Extended Kalman Filter – EKF*) desenvolvido com elementos de *AI* (*Artificial Intelligence*) (ZHAN; WAN, 2006), (HAYKIN, 2001). O algoritmo do filtro *EKF* consegue tratar com maior eficiência não linearidades da planta. Estas não linearidades estão presentes na grande maioria das plantas industriais e podem comprometer a variável medida e consequentemente a precisão dos resultados da predição (WELCH; BISHOP, 2001).

Existem alguns motivos para utilizar o *KF*, incorporado na arquitetura interna do controle preditivo MPC. As principais justificativas são:

- ✓ Utilização de modelo estocástico contidos nas equações do *KF* uma vez que, o processo de modelagem tem várias fontes de ruído;
- ✓ O algoritmo do *KF* considera que há ruído gaussiano em todas as medições;
- ✓ Prevê a incorporação do modelo de entradas não controláveis (perturbações não medidas) que influenciam a dinâmica do sistema (ruído de processo). O ruído de processo é inerente para alguns tipos de processos, podendo comprometer o desempenho de sistemas de controle;
- ✓ Precisão ou incerteza de medição dos sensores utilizados para a medição das variáveis de interesse afetadas pelo ruído de medição.

De maneira geral, o algoritmo do *KF* é dividido em duas partes, a primeira delas é a predição e a outra é a atualização. O algoritmo trabalha de maneira sequencial ou batelada, melhor dizendo, a etapa de predição dos estados só é iniciada depois do término da etapa de atualização das medições (sensores). Não obstante, é propício enfatizar que o tempo de execução do algoritmo é determinado pela capacidade de processamento do hardware, ou melhor, o tempo de predição dos estados pelo *KF* depende do desempenho dos recursos computacionais disponíveis onde a aplicação está instalada (*Kalman Filter*). Em geral, o tempo total de execução de um ciclo de predição dos estados do *KF* é da ordem de milissegundos, incluindo as etapas de determinação dos estados iniciais ou condições iniciais (WELCH; BISHOP, 2001), (BROOKNER, 1998).

O *KF* é usado na grande maioria dos algoritmos de controle preditivo MPC, sendo em muitos casos indispensável para determinar os estados iniciais e correntes do processo ou sistema. No controlador preditivo MPC do MATLAB™, a predição dos estados é executada pelo filtro de *Kalman* (*KF*). Trata-se de um observador de estados, isto é, um algoritmo matemático de predição dos estados, parte importante e fundamental para o mecanismo de predição do controlador MPC.

6.2 MODELO DE PREDIÇÃO NO CONTROLADOR MPC

A base de predição do MPC é seu estado corrente, x_c . Seu vetor de estados é:

$$x_c^T = [x_p^T(k) \quad x_{id}^T(k) \quad x_{od}^T(k) \quad x_n^T(k)] \quad (22)$$

onde:

x_c – é o estado do controlador, composto de $n_{xp} + n_{xid} + n_{xod} + n_{xn}$ variáveis de estado

x_p – é o vetor de estados do modelo da planta, com n_{xp} elementos

x_{id} – é o vetor de estados do modelo de perturbação de entrada, com n_{xid} elementos

x_{od} – é o vetor de estados do modelo de perturbação de saída, com n_{xod} elementos

x_n – é o vetor de estados do modelo de ruído de medição, com n_{nxx} elementos.

Os estados da planta são atualizados a cada nova medição de $u(k)$, $v(k)$ e $d(k)$. Os estados do controlador são então atualizados a cada nova medição de $u(k)$ e $v(k)$.

6.2.5 OBSERVADOR DE ESTADOS

As Equações (23) e (24) calculam a saída predita.

$$x_c(k+1) = A \cdot x_c(k) + B_n \cdot w_n(k) \quad (23)$$

$$y(k) = C \cdot x_c(k) + D \cdot u_0(k) \quad (24)$$

onde:

$$A = \begin{bmatrix} A_p & B_{pd} \cdot C_{id} & 0 & 0 \\ 0 & A_{id} & 0 & 0 \\ 0 & 0 & A_{od} & 0 \\ 0 & 0 & 0 & A_n \end{bmatrix}, \quad B = \begin{bmatrix} B_{pu} & B_{pv} & B_{pd} \cdot D_{id} & 0 & 0 \\ 0 & 0 & B_{id} & 0 & 0 \\ 0 & 0 & 0 & B_{od} & 0 \\ 0 & 0 & 0 & 0 & B_n \end{bmatrix},$$

$$C = \begin{bmatrix} C_p & D_{pd} \cdot C_{id} & C_{od} & \begin{bmatrix} C_n \\ 0 \end{bmatrix} \end{bmatrix}, \quad D = \begin{bmatrix} 0 & D_{pv} & D_{pd} \cdot D_{id} & D_{od} & \begin{bmatrix} D_n \\ 0 \end{bmatrix} \end{bmatrix}$$

Os sinais de entrada para o observador são as variáveis manipuladas e as perturbações medidas, além dos ruídos brancos para os modelos de perturbação e de ruído.

$$u_0^T(k) = [u^T(k) \quad v^T(k) \quad w_{id}^T(k) \quad w_{od}^T(k) \quad w_n^T(k)] \quad (25)$$

As saídas do observador são as n_y saídas adimensionais da planta. Os sinais de entrada e de saída são normalizados para ficarem adimensionais antes do início dos cálculos. O MPC executa a conversão dos modelos matemáticos do processo e das perturbações medidas e não medidas para o domínio em espaço de estados. Independentemente da representação do modelo da planta identificada ser na forma de matriz de ganho ou de função de transferência, o algoritmo interno do MPC converte os modelos identificados para o espaço de estados, isto é, o MPC do MATLAB™ só aceita representação das variáveis em espaço de estados (BEMPORAD; RICKER; OWEN, 2004), (BEMPORAD; MORARI; RICKER, 2015), (BEMPORAD; RICKER; MORARI, 2019).

No início de cada k -ésimo intervalo de controle, o estado do controlador é estimado de acordo com os seguintes passos:

1) Obter os dados:

$x_c(k|k-1)$ - Estimação do estado do controlador a partir do intervalo anterior de controle, $k-1$

$u^{act}(k-1)$ - MV aplicada na planta de $k-1$ a k (assumida como constante)

$u^{opt}(k-1)$ - MV ótimo recomendado pelo MPC, é usado na planta de $k-1$ a k

$v(k)$ - Perturbações atuais medidas

$y_m(k)$ - Saídas medidas atuais da planta

$B(u), B(v), u(k)$ e $v(k)$ - Colunas do parâmetro B do observador equivalentes às entradas

C_m - Linhas do observador de parâmetros C correspondentes às saídas medidas da planta

D_{mv} - Linhas e colunas do parâmetro do observador D correspondentes às saídas da planta e perturbações medidas

L, M - Matrizes constantes dos ganhos de Kalman

2) Recalcular $x_c(k|k-1)$ quando $u^{opt}(k-1)$ e $u^{act}(k-1)$ estiverem diferentes:

$$x^{rev}(k|k-1) = x_c(k|k-1) + B_u \cdot [u^{act}(k-1) - u^{opt}(k-1)] \quad (26)$$

3) Calcular a inovação:

$$e(k) = y_m(k) - [C_m \cdot x_c^{rev}(k|k-1) + D_m \cdot v(k)] \quad (27)$$

4) Atualizar a estimativa do estado do controlador para contabilizar as últimas medidas:

$$x_c(k|k) = x_c^{rev}(k|k-1) + M \cdot e(k) \quad (28)$$

As Equações (29) e (30) são usadas para o cálculo de y_p . O M_{MPC} permite o uso de ganhos ou fatores de escala para cada variável de entrada e de saída da planta:

$$x_p(k+1) = A_p \cdot x_p(k) + B \cdot S_i \cdot u_p(k) \quad (29)$$

$$y_p = S_o^{-1} \cdot C \cdot x_p(k) + S_o^{-1} \cdot D \cdot S_i \cdot u_p(k) \quad (30)$$

onde:

S_i é uma matriz diagonal dos ganhos de entrada em unidades de engenharia

S_o é uma matriz diagonal dos ganhos de saída em unidades de engenharia

x_p é o vetor de estados da planta em unidades de engenharia. Não é realizada multiplicação por uma escala nas variáveis de estado

u_p é um vetor adimensional das variáveis de entrada da planta

y_p é um vetor adimensional das variáveis de saída da planta

O modelo resultante da planta tem a seguinte forma equivalente:

$$x_p(k+1) = A_p \cdot x_p + B_{pu} \cdot u(k) + B_{pv} \cdot v(k) + B_{pd} \cdot d(k) \quad (31)$$

$$y_p(k) = C_p \cdot x_p(k) + D_{pu} \cdot u(k) + D_{pv} \cdot v(k) + D_{pd} \cdot d(k) \quad (32)$$

onde:

C_p é $S_o^{-1} \cdot C$ e B_{pu}, B_{pv} e $B_{pd}B \cdot S_i$, D_{pu}, D_{pv} e D_{pd} são as colunas de $S_o^{-1} \cdot D \cdot S_i$.

Por último, $u(k)$, $v(k)$ e $d(k)$ são as variáveis manipuladas, as perturbações medidas e as perturbações não medidas, todas adimensionais. Esse modelo não permite a realimentação direta de qualquer variável manipulada para qualquer saída da planta ($D_{pu} = 0$).

Após o cálculo de $u^{opt}(k)$ pelo QP, o controlador se prepara para o próximo intervalo de controle considerando que as entradas desconhecidas $w_{id}(k)$, $w_{od}(k)$ e $w_n(k)$ assumem seu valor médio (zero) entre os tempos k e $k+1$. O controlador então prediz o impacto das entradas conhecidas e da inovação da seguinte forma:

$$x_c(k+1|k) = A \cdot x_c^{rev}(k|k-1) + B_u \cdot u^{opt}(k) + B_v \cdot v(k) + L \cdot e(k) \quad (33)$$

6.2.6 CÁLCULO DOS GANHOS DE KALMAN NO ESTADO ESTACIONÁRIO

A ferramenta MATLAB *Model Predictive Control Toolbox*® usa a função *kalman* para calcular os ganhos L e M . As hipóteses consideradas nesse cálculo são:

- a) Os observadores de estado A, B, C e D são invariantes no tempo;
- b) Os estados do controlador, x_c , são detectáveis;
- c) As entradas estocásticas $w_{id}(k)$, $w_{od}(k)$ e $w_n(k)$ são ruídos brancos independentes, cada um com média zero e covariância identidade.

Ruídos brancos adicionais $w_u(k)$ e $w_v(k)$ com as mesmas características são adicionados a u_k e v_k , respectivamente. Sem perda de generalidade, com as entradas $u(k)$ e $v(k)$ em zero, o efeito das entradas aleatórias e das saídas da planta medida é:

$$x_c(k+1) = A \cdot x_c(k) + B \cdot w(k) \quad (34)$$

$$y_m(k) = C_m \cdot x_c(k) + D_m \cdot w(k) \quad (35)$$

sendo que $w(k) = [w_u^T(k) \ w_v^T(k) \ w_{id}^T(k) \ w_{od}^T(k) \ w_n^T(k)]$.

As entradas para a função *kalman* são os parâmetros A e C_m das seguintes matrizes de covariância:

$$Q = E\{B \cdot w \cdot w^T \cdot B^T\} = B \cdot B^T \quad (36)$$

$$R = E\{D_m \cdot w \cdot w^T \cdot D_m^T\} = D_m \cdot D_m^T \quad (37)$$

$$N = E\{B \cdot w \cdot w^T \cdot D_m^T\} = B \cdot D_m^T \quad (38)$$

onde $E\{\dots\}$ é o valor esperado ou esperança matemática.

6.2.7 PREDIÇÃO DAS VARIÁVEIS DE SAÍDA

O MPC requer a predição das saídas sem ruído futuras da planta usadas na otimização. No controle de intervalo k , os dados requeridos são:

- ✓ p – Horizonte de predição;
- ✓ $x_c(k|k)$ – Estimções dos estados do controlador;

- ✓ $v(k)$ – Perturbações medidas de entrada atuais;
- ✓ $v(k + i|k)$ onde i varia de 1 até $p - 1$.

A, B_u, B_v, C e D_v – constantes do observador de estados, onde B_u, B_v e D_v são colunas das matrizes B e D correspondentes às entradas u e v . D_u é uma matriz composta por zeros porque não há retroalimentação direta.

As predições assumem que as entradas de ruído branco são zero (valor esperado). Além disso, as saídas preditas da planta são consideradas livres de ruído. Por causa disso, os termos que envolvem os estados de ruído de medição desaparecem das equações do observador de estados. Isso é equivalente a zerar os últimos n_{xn} elementos de $x_c(k|k)$.

No primeiro passo, $i = 1$, o observador realiza a predição:

$$x_c(k + 1|k) = A \cdot x_c(k|k) + B_u \cdot u(k|k) + B_v \cdot v(k|k) \quad (39)$$

Para i de 2 até p , o observador de estados realiza a predição:

$$x_c(k + i|k) = A \cdot x_c(k + i - 1|k) + B_u \cdot u(k + i - 1|k) + B_v \cdot v(k + i - 1|k) \quad (40)$$

Em todos os passos, as saídas sem ruído preditas são:

$$y(k + 1|k) = C \cdot x_c(k + i|k) + D_v \cdot v(k + i|k) \quad (41)$$

Essas equações empregam entradas e saídas adimensionais.

6.2.8 PROBLEMA DE OTIMIZAÇÃO

A otimização usada no MATLAB é a QP (*Quadratic Programming*) (FRANK; WOLFE, 1956). Com o valor de $x_c(k)$ disponível, é possível calcular as entradas ótimas via QP no intervalo k . O $u^{opt}(k)$ calculado é então aplicado na planta entre os intervalos de controle k e $k + 1$, que é a meta primária do MPC. QP é o processo de solução de um tipo especial de problema de otimização, dado por uma função quadrática linear com restrições (MATHWORKS, 2019), que gera as entradas ótimas de controle. O tamanho desse vetor depende do horizonte de controle m .

A função objetivo do M_{MPC} é:

$$J(z_k) = J_y(z_k) + J_u(z_k) + J_{\Delta u}(z_k) + J_\varepsilon(z_k) \quad (42)$$

onde $J_y(z_k)$ é a função custo escalar de desempenho do controlador para seguir uma trajetória:

$$J_y(z_k) = \sum_{j=1}^{n_y} \sum_{i=1}^p \left\{ \frac{w_{i,j}^y}{s_j^y} \cdot [r_j(k + i|k) - y_j(k + i|k)] \right\}^2 \quad (43)$$

onde:

$r_j(k + 1|k)$ – valores de referência para a saída da planta, em unidades de engenharia

$y_j(k + 1|k)$ – saídas previstas da planta, em unidades de engenharia

$w_{i,j}^y$ – ganhos adimensionais de sintonia para a j -ésima saída

s_j^y – Fator de escala para a j -ésima saída, em unidades de engenharia

Os outros custos são similares a $J_y(z_k)$ e não são apresentados nesta subseção. Todavia poderão ser confrontados através da documentação do MATLAB™.

6.2.9 GERAÇÃO DOS SINAIS DAS PERTURBAÇÕES E RUÍDOS

O MATLAB™ usa o modelo genérico em espaço de estados apresentado nas Equações (46) e (47) para a geração dos sinais de perturbação das entradas não medidas e da saída.

$$x_d(k + 1) = A_d \cdot x_d + B_d \cdot w_d(k) \quad (44)$$

$$d_k(k) = C_d \cdot x_d + D_d \cdot w_d(k) \quad (45)$$

onde d_k é a perturbação com ruído branco gerada.

Para os ruídos das saídas previstas e das saídas medidas:

$$x_n(k + 1) = A_n \cdot x_d + B_n \cdot w_n(k) \quad (46)$$

$$d_n(k) = C_n \cdot x_n + D_n \cdot w_n(k) \quad (47)$$

onde d_n é o ruído branco gerado.

No caso específico da perturbação da entrada não medida, objeto desse trabalho, as equações se tornam:

$$x_{id}(k + 1) = A_{id} \cdot x_{id} + B_{id} \cdot w_{id}(k) \quad (48)$$

$$d_k(k) = C_{id} \cdot x_{id} + D_{id} \cdot w_{id}(k) \quad (49)$$

onde A_{id} , B_{id} , C_{id} e D_{id} são matrizes constantes no espaço de estados, $x_{id}(k)$ é um vetor de $n_{xid} \geq 0$ estados do modelo de perturbação de entrada, $d_k(k)$ é um vetor de n_d perturbações de entrada não medidas e adimensionais e $w_{id}(k)$ é um vetor de $n_{id} \geq 1$ entradas de ruídos brancos adimensionais, tendo média 0 e variância unitária.

6.2.10 IMPLEMENTAÇÃO DO MODELO NO MATLAB™

O MATLAB™ permite criar funções no formato de *scripts*, que são módulos escritos em sua linguagem para realizar as mais diversas soluções matemáticas em um ambiente de computação numérica. Também permite criar modelos no pacote *Simulink*, usando blocos que contêm funcionalidades próprias, onde suas entradas e saídas são interconectadas. O autor fez uso de *scripts*, que permitem maior controle sobre o que está sendo desenvolvido e contêm mais funcionalidades disponíveis do que no *Simulink*. A estratégia para gerar os *scripts* foi a de dividir as funcionalidades em pequenos módulos, onde cada módulo era responsável por executar uma certa função unitária para o sistema. Esse formato de modularização é típico de sistemas baseado em funções.

Os módulos, apresentados no Apêndice A, são:

1. Criação do modelo da planta – usa as entradas e as saídas resultantes da identificação realizada do forno e seus correspondentes sinais para gerar o controlador MPC. Esse módulo permite a separação da perturbação de entrada não medida do modelo criado;
2. Parametrização dos horizontes – define os horizontes de controle e de predição;
3. Parametrização das restrições – define as restrições de entrada da planta;
4. Configuração de ganhos de escala – define os ganhos de escala de entrada e de saída da planta;
5. Parametrização dos pesos de saída – define os pesos usados pelos sinais de saída da planta;
6. Parametrização dos pesos das entradas de acordo com curva característica (ganho, constante de tempo e taxa de variação do curso);
7. Criação das referências – para geração dos sinais de referência para as manipuladas, incluindo a suavização do sinal de *set-point* através de uma função de transferência para simulação do controlador;
8. Simulação da planta com perturbação não medida de entrada com modelo H – para verificar o desempenho do MPC para a rejeição de perturbação, com uso do modelo H ;
9. Simulação da planta com perturbação não medida de entrada sem modelo H – para verificar o desempenho do MPC para a rejeição de distúrbio, sem uso do modelo H , com ganho unitário (sem tratamento da perturbação);
10. Plotagem dos resultados – para apresentar graficamente os resultados das simulações;
11. Simulação da planta – módulo principal que executa os demais.

Ademais, para as otimizações mono-objetivo e multi-objetivo foram criados módulos para a otimização em si e módulos para a simulação do controlador, tendo como saída o índice de custo usado.

6.2.11 CRIAÇÃO DO MPC NO MATLAB™

O controlador foi implementado no MATLAB usando $m = 2$ e $p = 40$, após inspeção visual dos resultados apresentados e dos critérios IAE calculados. Somente o uso desses critérios não se mostrou satisfatório porque havia casos em que a resposta com menor IAE possuía um sobressinal grande e estabilizava rapidamente em contrapartida a uma resposta de estabilização mais lenta, porém quase sem sobressinal.

O comando *review* do MPC Toolbox realiza uma análise relativamente profunda do controlador gerado, indicando possíveis problemas de restrição, instabilidade, entre outros. Não foi encontrado problema algum de estabilidade ou de predição com o controlador gerado.

6.3 SINTONIA DO CONTROLADOR MPC

A sintonia do M_{MPC} foi realizada com o propósito de gerar um controlador padronizado, de modo a servir como base para a análise posterior, relacionada com os aspectos de desempenho do controlador MPC com e sem o tratamento (rejeição) das perturbações não medidas. Além disso, o MATLAB ao criar um controlador MPC, gera ganhos sub-ótimos de sintonia. Esses ganhos sub-ótimos não representam uma solução ótima de minimização do erro, isto é, são ganhos iniciais ou ponto de partida para a sintonia do controlador.

A sintonia do M_{MPC} foi feita através de um algoritmo genético, que permite a otimização multi-objetivo, conhecido como MOGA (*Multi-Objective Genetic Algorithm*) ou Algoritmo Genético Multi-Objetivo (CENSOR, 1977). A implementação específica, disponível no pacote de Otimização Global do MATLAB, usa uma variação de um algoritmo genético elitista intitulado NSGA-II (*Fast-Non-Dominated Sorting Genetic Algorithm*) (DEB, 2001).

A necessidade de se usar um algoritmo multi-objetivo é que a otimização através do somatório dos erros discretos, por exemplo, através dos critérios *Integral Absolute Error* (IAE), *Integral Squared Error* (ISE) ou do *Integral of Time and Absolute Error* (ITAE) ou qualquer outro cálculo de

penalização, pode desprezar uma ou mais variáveis de saída em comparação com as referências, gerando uma sub-otimização. O MOGA gera um conjunto de parâmetros conhecido como fronteira de Pareto, em que é garantido que a mudança em qualquer um dos elementos do vetor Utopia irá degradar o valor ótimo obtido.

As variáveis a serem otimizadas são um conjunto de parâmetros independentes que podem ser mudados para melhorar, de acordo com algum critério, o desempenho de um sistema ou processo. Restrições são requisitos de projeto e devem ser satisfeitas no projeto ótimo.

Tanto o objetivo quando as restrições são funções das variáveis de decisão (ZELANY, 1974). Portanto, o problema de otimização MOGA pode ser resumido como sendo descobrir os valores das variáveis de decisão que minimizam ou maximizam as funções objetivo e satisfazem as restrições de projeto. Um problema de otimização multi-objetivo é formulado como segue:

$$\begin{aligned} \min f(x) &= \{f_1(x), f_2(x), \dots, f_n(x)\} \\ \text{s. a } g_j(x) &< 0 \end{aligned} \quad (50)$$

onde x são as variáveis de decisão, $f_1(x), \dots, f_n(x)$ são as múltiplas funções objetivo e $g_j(x)$ são as restrições.

Quando se trabalha com múltiplos objetivos, os relacionamentos naturais “melhor que” e “pior que”, entre soluções alternativas não mais se mantêm, e o relacionamento entre indivíduos é descrito como um relacionamento de dominação, levando a um conjunto Pareto-ótimo ao invés de um único resultado ótimo. A dominação é definida para quaisquer duas soluções x_1 e x_2 , sendo que se diz que x_1 domina x_2 se essas condições forem satisfeitas:

- a) x_1 não é pior que x_2 em todos os objetivos;
- b) x_1 é estritamente melhor que x_2 em pelo menos um objetivo.

Se nenhuma dessas condições se mantém, então x_1 não domina x_2 .

O conjunto não dominado é definido como o conjunto de todas as soluções que não são dominadas por qualquer outra solução no espaço de busca. O conjunto global Pareto-ótimo ocorre quando não há outra solução em todo o espaço de busca que domine qualquer outro membro do conjunto.

A partir do conjunto Pareto-ótimo é então possível escolher uma solução que melhor se adeque às restrições. A otimalidade de Pareto é definida como um conjunto onde, cada elemento é uma solução possível para a qual nenhuma outra solução pode ser melhor em todos os objetivos da otimização. Para o caso bidimensional, a fronteira de Pareto é uma curva, mostrada Figura 81, que ilustra o compromisso entre os dois objetivos.

A otimização foi feita através da aplicação de referências em degraus suavizados provenientes de um otimizador financeiro, que gera valores de referência baseado na maximização da rentabilidade do processo. As referências aplicadas nessa otimização foram escalares e, portanto, mais restritivas que a manutenção do processo dentro de camadas e, portanto, mantém a validade dos resultados obtidos.

Para o cálculo do custo foi usado o critério IAE :

$$IAE_i = \sum_{t=0}^{T_f} abs(r_i - y_i) \quad (51)$$

Figura 81 - Fronteira de Pareto.

Fonte: Autor.

onde $T_f = 360$ min é o tempo de simulação necessário para a acomodação das saídas, i variando de 1 até n_y é a quantidade de somatórios de saída, y_i são as saídas do controlador na ordem apresentada e r_i são os valores de referência para cada saída. Consequentemente, para o MOGA, o IAE é um vetor de n_y elementos. O critério IAE é extensamente usado como uma métrica para comparar desempenho, pois sua equação considera a soma das áreas acima e abaixo do valor de referência, retornando um conjunto de parâmetros ótimos para sintonia do controlador preditivo MPC (MARLIN, 1996), (SILVEIRA, 2012), (ARAUJO, 2017), (SILVA, 2018), (PINHEIRO, 2018).

As referências para as três variáveis controladas são fixas e iguais a seus valores nominais. Os valores nominais das variáveis controladas são apresentados na Tabela 20.

Tabela 20 – Valores nominais das variáveis de saída – (variáveis controladas).

OV	Valor nominal
TIC-23099	558,16
AIC-23003	2,36
PIC-23039	4,91

Fonte: Autor.

Os parâmetros usados na busca foram os pesos das variáveis de saída vistos na Equação (52). Os pesos das variáveis de entrada não podem ser usados na otimização porque na implantação do MATLAB™ isso consideraria que há entradas ótimas para esse controle, o que não é o caso.

$$\begin{aligned} &\min IAE(w_i) \\ &\quad s. a \\ &w_{i_{min}} < w_i < w_{i_{max}} \end{aligned} \quad (52)$$

Os limites mínimos para a busca foram:

$$w_{o_{min}} = [0 \ 0 \ 0]$$

E os máximos foram:

$$w_{o_{max}} = [100 \ 100 \ 100]$$

A otimalidade do Pareto cria um vínculo de compromisso na atribuição dos objetivos, não sendo factível realocá-los para que todos os parâmetros sejam ótimos. Quando se consideram dois objetivos, a otimalidade do Pareto é uma condição que torna inviável melhorar um dos objetivos, sem necessariamente piorar o outro. A otimização multi-objetivo é extensivamente usada para determinar a fronteira do Pareto, ou melhor, o conjunto de pontos realizáveis (curva de Pareto). Na Figura 82 considera-se um problema de otimização de dois objetivos. O primeiro objetivo é o menor ganho da saída e o segundo objetivo é o menor *IAE*. Analisando a figura se pode afirmar que o objetivo 1 (menor ganho da saída) é dominado pelo objetivo 2 (menor *IAE*), uma vez que é realizável deslocar-se do objetivo 1 para o objetivo 2, melhorando ambos objetivos. A otimização multi-objetivo realiza a busca da fronteira de Pareto através de algoritmos genéticos. Enfatiza-se que a Figura 82 deveria ser de 6 variáveis (3 para cada eixo), porém o MATLAB plota o menor valor do primeiro objetivo (menor *IAE*) e o menor valor do segundo objetivo (menor ganho de saída). Como já citado, a Tabela 21 não contempla escala, a otimização é somente dos ganhos de saída. Na Figura 82 é vista a fronteira de Pareto, resultado da sintonia do controlador MPC.

Figura 82 - Plotagem da fronteira de Pareto.

Fonte: Autor.

A otimização MOGA gerou 70 vetores. Para escolher a solução mais adequada para o MPC, o critério qualitativo de suavidade na resposta foi usado. A escolha foi feita por inspeção visual. O ponto usado é visto na Tabela 21.

Tabela 21 - Valores de escala e de ganho para as variáveis manipuladas e controladas.

Variável	Fator	Valor
PIC-23039	Ganho	4,94
TIC-23099	Ganho	64,92
AIC-23001	Ganho	89,64

Fonte: Autor.

As entradas para a comparação do M_{MPC} e do $M_{MPC_{opt}}$ são vistas nas Figura 83 a 86.

Figura 83 - Entradas do M_{MPC} e do $M_{MPC_{opt}}$.

Fonte: Autor.

Figura 84 Saídas do M_{MPC} e do $M_{MPC_{opt}}$.

Fonte: Autor.

Figura 85 Saídas do M_{MPC} e do $M_{MPC_{opt}}$.

Fonte: Autor.

Figura 86 Saídas do M_{MPC} e do $M_{MPC_{opt}}$.

Fonte: Autor.

A Tabela 22 apresenta ao valor do critério *IAE* antes e após a sintonia do controlador usando o método MOGA e os respectivos ganhos percentuais.

Tabela 22 – Valores do critério *IAE* para a planta sem e com sintonia do controlador.

Variável de Processo	<i>IAE</i> sem sintonia	<i>IAE</i> com sintonia	Ganho (%)
TIC-23099	591,87	554,38	6,76
AIC-23001	81,38	52,16	56,01
PIC-23039	46,30	44,50	4,03

Fonte: Autor.

A melhora na energia gasta pelos atuadores é vista na Tabela 23. A fórmula usada para seu cálculo é a Integral da Entrada Absoluta ou *IAU*:

$$IAU_i = \sum_{t=0}^{T_f} abs(u_i) \quad (53)$$

onde t é o tempo, $T_f = 360 \text{ m}$ é o tempo de simulação (tempo necessário para a acomodação das saídas), i variando de 1 até n_y é a quantidade de somatórios de saída e u_i são as entradas geradas pelo controlador na ordem apresentada.

Tabela 23 - Resultados da integral do esforço *IAU* para os atuadores do forno.

Variável de Processo	<i>IAU</i> sem sintonia	<i>IAU</i> com sintonia	Ganho (%)
FIC-23027.SP	424272	422306	0,47
FIC-23028.SP	645879	636405	1,49
FIC-23025.SP	18175666	18016477	0,88

Fonte: Autor.

CAPÍTULO 7

COMPARAÇÃO ENTRE MPC COM E SEM MODELO H

Para responder a hipótese formulada nesta tese, apresenta-se neste capítulo a sustentação teórica para responder à questão sobre o desempenho dos controladores com e sem modelo de perturbação H , o desenvolvimento dos controladores e a comparação entre seus desempenhos.

7.1 COMPROVAÇÃO TEÓRICA

A hipótese é que, em condições similares de operação, o desempenho esperado do M_{MPC} com tratamento para uma perturbação de entrada não medida seja melhor que com um controlador MPC sem um modelo para o tratamento dessa perturbação. A perturbação não modelada e, portanto, não tratada, deteriorará os erros entre as referências e as saídas medidas.

Imperfeições no modelo, limitações da planta e perturbações não medidas provocam desvios nos valores demandados das MVs. O M_{MPC} usa a saída corrente mais um modelo de perturbação para calcular as atuações futuras na planta, através de um problema de otimização com ou sem restrições. As atuações presentes e futuras otimizadas consideram em seus cálculos x_c , os estados do controlador, que incluem as perturbações de entrada d , de saída y_{od} e do ruído de medição y_n em sua formulação, para calcular as ações de controle apropriadas. Entretanto, conforme ressaltado na Subseção 6.2.5, o algoritmo do controlador preditivo MPC do MATLAB™ executa todas as operações matemáticas em espaço de estados. Durante a fase de inicialização do programa é realizada, entre outras, a conversão da função de transferência ou matriz de ganho em variáveis de estados (BEMPORAD; MORARI; RICKER, 2015), (BEMPORAD; RICKER; MORARI, 2019).

A base para a predição dos estados futuros no M_{MPC} é o vetor de estados do controlador $x_c^T(k)$, definido na Equação (22), repetida aqui, que contém o estado atual do controlador e que inclui as perturbações de entrada e de saída e do ruído de medição.

$$x_c^t = [x_p^T(k) \quad x_{id}^T(k) \quad x_{od}^T(k) \quad x_n^T(k)] \quad (54)$$

As saídas previstas, por sua vez, dependem de x_c .

$$y(k+1|k) = C \cdot x_c(k+i|k) + D_v \cdot v(k+i|k) \quad (55)$$

No processo de otimização, um dos termos é o desempenho escalar para o rastreamento de uma referência, que é o que se busca aqui. Esse custo, por sua vez, possui em sua formulação a saída

predita $y(k + 1|k)$. Como $r_j(k)$ é constante durante uma iteração do controlador, a ausência de um modelo de perturbação durante a geração de $y_j(k)$ predito irá piorar o tratamento da perturbação, definido na Equação (43), também repetida aqui,

$$J_y(z_k) = \sum_{j=1}^{n_y} \sum_{i=1}^p \left\{ \frac{w_{i,j}^y}{s_j^y} \cdot [r_j(k + i|k) - y_j(k + i|k)] \right\}^2 \quad (56)$$

Com isso, a perturbação que irá ser tratada de forma ótima pelo M_{MPC} se torna um elemento relevante no cálculo de qual é a efetiva perturbação que o controlador consegue tratar, mesmo que, na prática, a perturbação em uma planta real seja igual para diferentes $r_j(k)$.

7.2 MODELO DE PERTURBAÇÃO

A análise do desempenho do M_{MPC} com um modelo de perturbação de entrada próximo à real perturbação sofrida pelas variáveis controladas, obtido dos resíduos da identificação do forno e que passa pela dinâmica do sistema é então comparado ao mesmo modelo obtido da planta mas, dessa vez, com o modelo de perturbação de entrada. O modelo de perturbação obtido a partir dos resíduos da identificação, porém, depende da qualidade da identificação realizada e da separação do que é perturbação e do que é ruído de medição.

Os ruídos de medição, incluindo ruídos elétricos, erros de amostragem, erros de calibração de sensores de campo (instrumentação), entre outros, que reduzem a acurácia da medição, são desprezados, por serem de baixa potência em comparação com a perturbação propriamente dita. Essa afirmação pode ser feita pois o pessoal de instrumentação e automação industrial da SIX está constantemente realizando manutenção preditiva e preventiva nos sensores e efetuando reparos e substituição quando detectado anomalias.

A estratégia adotada neste trabalho com relação à dependência do modelo de perturbação de entrada da qualidade da identificação realizada é comparar o desempenho do M_{MPC} face a distúrbios de entrada. Se o modelo adotado para essas perturbações estiver adequado, ele será capaz de rejeitá-las. A Figura 87 mostra o modelo proposto para a simulação da planta com o modelo H desenvolvido a partir dos resíduos da identificação do forno.

Os modelos do processo e das perturbações não medidas foram encapsulados e parametrizados no controlador M_{MPC} com modelo H . Estes modelos estão disponíveis na Subseção 5.7.3 e na Seção 5.9, sendo que o modelo do processo é G e da perturbação é H :

$$G_{\text{Modelo de processo}} = [G_{TIC}; G_{PIC}; G_{AIC}]$$

$$H_{\text{Modelo de perturbações não medidas}} = [H_{TIC}; H_{PIC}; H_{AIC}]$$

Figura 87 - Controlador MPC com modelo H para a análise da perturbação de entrada.

Fonte: Autor.

A estrutura de um MPC cujo modelo interno não inclua as características das perturbações não medidas é vista na Figura 88. A razão para tal desconhecimento é que não há modelo e sim uma simples multiplicação por um ganho unitário no espaço de estados. O ganho unitário adimensional faz com que as perturbações de entrada não medidas não sejam tratadas, melhor dizendo, quando se ajusta a matriz H para um valor unitário (1), o sinal de perturbação não-medida é multiplicado por este valor (ganho unitário). Neste caso, o sinal de perturbação não-medida não será tratado pelo filtro de Kalman (KF). Não obstante, o efeito desta parametrização (ganho unitário) é fazer com que a rejeição à perturbação pelo M_{MPC} não seja eficaz e nem integrada e, assim, gere erros de estado estacionário. O ganho estático configurado para esse canal é a matriz identidade:

$$D_{MPC_s} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

e as matrizes A , B e C não existem.

Figura 88-Modelo proposto para a análise da perturbação de entrada.

Fonte: Autor.

Como já citado no início do Capítulo 6, quando o modelo das perturbações não medidas não é definido, o MATLAB considera, por padrão, que suas entradas são ruído branco de média zero e variância unitária e, para tratar esse sinal, um integrador com ganho unitário adimensional é adicionado para cada canal de perturbação não medida. O controlador desenvolvido no MPC *Designer* do MATLAB® modela distúrbios de entrada não medida como ruído gaussiano integrado.

Todavia, a *Toolbox* do MPC *Designer* MATLAB®, disponibiliza para o projetista a opção de reconfiguração dos integradores do modelo de perturbações de entrada não medida, isto é, de acordo com as características do sinal de perturbação não medida identificada (rampa, gaussiano, senoidal, variância, etc) pode-se atribuir uma curva associada a uma variância ou simplesmente manter o ganho unitário dos integradores e variância nula. Através destas parametrizações dos integradores possibilita-se a comparação entre os controladores MPC com e sem modelo H .

Esta é uma alternativa adequada e pode ser aplicada quando os dados do processo, foram coletados em condições próximas às condições nominais de operação da planta. Neste caso, o modelo no espaço de estados encapsula a dinâmica de perturbações estocásticas do processo identificado. Uma vez encapsulado e parametrizado o modelo identificado das perturbações não medidas, o controlador MPC deverá rejeitar estas perturbações de entrada da planta, mantendo o sistema de controle robusto a distúrbios estocásticos (BEMPORAD; MORARI; RICKER, 2015), (BEMPORAD; RICKER; MORARI, 2019). Conforme destacado, o MPC do MATLAB™, permite a reconfiguração do módulo integrador do controlador, através da definição do modelo (H) e dos sinais desse modelo para o tratamento das perturbações de entrada (perturbações não medidas).

No entanto, como o objetivo desta tese é comparar o desempenho entre os controladores MPC com e sem modelo H , é usado o padrão gerado pelo MATLAB, ou seja, um integrador com ganho unitário para o controlador sem H . No caso do controlador preditivo M_{MPC} com modelo H , será encapsulado (inserido) o modelo de perturbação não medida, identificado, e também será feita a parametrização do sinal de entrada do tipo gaussiano. Assim, compara-se aqui o desempenho de um controlador M_{MPC} com H , que o auxilia a rejeitar perturbações não medidas, com o de um controlador M_{MPC} sem H e somente com um ganho unitário nas entradas de perturbação não medidas de entrada. Essa estrutura tem como fundamento a Equação (32), repetida aqui.

$$y_p(k) = C_p \cdot x_p(k) + D_{pu} \cdot u(k) + D_{pv} \cdot v(k) + D_{pd} \cdot d(k) \quad (57)$$

Às saídas preditas $y_p(k)$ do modelo da planta interna ao M_{MPC} são somadas as perturbações $D_{pd} \cdot d(k)$.

7.3 COMPARAÇÃO DOS M_{MPC} COM E SEM MODELO H

Com a definição dos dois controladores e de suas estratégias de rejeição à perturbação, foi realizada uma comparação entre o critério *IAE* (*Integral Absolute Error*) resultante de simulações para várias condições de perturbação e de mudanças de *set-point*.

A ferramenta computacional MATLAB™ disponibiliza os critérios *ISE*, *IAE*, *ITSE* e *ITAE*. Estes critérios são chamados de função de sensibilidade. A função *IAE* fornece uma medida absoluta da diferença entre as saídas e o valor de referência, e as entradas em relação ao alvo da função de controle. Os critérios *ISE*, *IAE*, *ITSE* e *TAE* retornam de resultados escalares sobre o desempenho da função objetivo do controlador MPC.

Estas funções também podem ser utilizadas na sintonia do controlador preditivo MPC, ou seja, através da função sensibilidade é possível encontrar os pesos de ajuste ou parametrização do controlador. Conforme destacado no texto, será utilizado o critério *IAE* como métrica para à análise comparativa relacionado com a *performance* dos controladores com e sem modelo de perturbação não medida.

7.3.1 REJEIÇÃO À PERTURBAÇÃO

A perturbação é inserida nos canais da perturbação não medida de entrada do modelo do MPC para cada variável controlada, ou seja, ela é injetada nas MOs. As variâncias dessas perturbações a $d_r = [0,0112 \ 0,0013 \ 0,0001]$ foram obtidas a partir das variâncias dos resíduos encontrados na identificação realizada no Capítulo 5. No entanto, para simulação da perturbação estocástica H utilizou-se uma função randômica (*rand*) para gerar um sinal de ruído branco gaussiano, correlacionado, com média zero e variância do modelo identificado.

Para a primeira análise foi aplicada a perturbação d_r a partir de $t = 10$ min e tempo de simulação $T = 120$ min. As Figura 89 a 92 exibem os resultados do controlador com e sem o modelo de perturbação.

Figura 89 - Resposta de rejeição a perturbação da TIC-23099 – MPC com e sem modelo de perturbação.

Fonte: Autor.

Figura 90 - Resposta da rejeição à perturbação na AIC-23001 - MPC com e sem modelo de perturbação.

Fonte: Autor.

Figura 91 - Resposta de rejeição à perturbação na PIC-23039 – MPC com e sem modelo de perturbação.

Fonte: Autor.

Figura 92 - Resposta das variáveis manipuladas a MPC com e sem modelo H .

Fonte: Autor.

A Tabela 24 exibe o valor do critério IAE da simulação com e sem modelo H para a TIC-23099, AIC-23001 e PIC-23099.

Tabela 24 – Valor do critério IAE da rejeição à perturbação.

Variável de Processo	IAE sem H	IAE com H
TIC-23099	1,6892	1,4089
AIC-23001	0,1015	0,0958
PIC-23039	0,0864	0,0830

Fonte: Autor.

Para a segunda análise da resposta a perturbações, foi aplicada uma perturbação com variância $d = [10 \ 0 \ 0]$ a partir de $t = 10$ min, com $T = 360$ min, para verificar a capacidade do M_{MPC} de rejeitar um grande distúrbio na TIC-23099. O resultado é apresentado na Figura 93.

Figura 93 - Curva de resposta a perturbação – TIC-23099.

Fonte: Autor.

A Tabela 25 apresenta o valor do critério *IAE* da simulação com e sem modelo *H* da TIC-23099.

Tabela 25 – Critério *IAE* da rejeição à perturbação para a TIC-23099.

Variável de Processo	<i>IAE</i> sem <i>H</i>	<i>IAE</i> com <i>H</i>
TIC-23099	1807,56	1117,23

Fonte: Autor.

Para a terceira análise da resposta a perturbações, foi aplicada uma perturbação com variância $d = [0 \ 10 \ 0]$ a partir de $t = 10$ min, para verificar a capacidade do M_{MPC} de rejeitar um grande distúrbio na AIC-23003. O resultado é apresentado na Figura 94.

Figura 94 - Curva de resposta a perturbação – AIC-23001.

Fonte: Autor.

A Tabela 26 apresenta o critério *IAE* da simulação com e sem modelo *H* da AIC-23001.

Tabela 26 – Critério *IAE* da rejeição à perturbação para a AIC-23001.

Variável de Processo	IAE sem <i>H</i>	IAE com <i>H</i>
AIC-23001	247,76	240,12

Fonte: Autor.

Para a quarta análise da resposta a perturbações, foi aplicada uma perturbação com variância $d = [0 \ 0 \ 2]$, para verificar a capacidade do M_{MPC} de rejeitar um grande distúrbio na PIC-23039. O resultado é apresentado na Figura 95.

Figura 95 - Curva de resposta a perturbação – PIC-23039.

Fonte: Autor.

A Tabela 27 apresenta o critério *IAE* da simulação com e sem modelo *H* da PIC-23039.

Tabela 27 – Critério *IAE* da rejeição à perturbação para a PIC-23039.

Variável de Processo	<i>IAE</i> sem <i>H</i>	<i>IAE</i> com <i>H</i>
PIC-23039	128,75	120,49

Fonte: Autor.

7.3.2 REJEIÇÃO À PERTURBAÇÃO COM MUDANÇA DE *SET-POINT*

Esta análise visa verificar a capacidade de rejeição a distúrbio em novos patamares de *set-point* e de distúrbios. A partir de $t = 25$ min são aplicados degraus no *set-point* com valores $r = [15 \ -1 \ -1]$ somados aos valores nominais e a perturbação de variância d_r chega ao forno aos $t = 50$ min. A Figura 96 mostram a resposta do controlador MPC com e sem modelo *H*.

Figura 96 - Curva de resposta de rejeição a perturbação com mudança de *set-point* – TIC-23099.

Fonte: Autor.

Figura 97 - Curva de resposta a perturbação com mudança de *set-point* – AIC-23001.

Fonte: Autor.

Figura 98 - Curva de resposta a perturbação com mudança de *set-point* – PIC-23039.

Fonte: Autor.

A Tabela 30 apresenta o valor do critério *IAE* das simulações com mudança de *set-point* e injeção de perturbação nas três variáveis de perturbação de entrada simultaneamente.

Tabela 28 – Critério *IAE* da rejeição à perturbação para a PIC-23039.

Variável de Processo	<i>IAE</i> sem <i>H</i>	<i>IAE</i> com <i>H</i>
TIC-23099	2105,56	1477,15
AIC-23001	52,51	47,06
PIC-23039	49,77	44,11

Fonte: Autor.

7.3.3 REJEIÇÃO A DISTÚRBO CONSTANTE

Para se analisar o caso de um distúrbio no forno da SIX possuir um caráter constante, portanto sem variância, foram simuladas condições onde a magnitude do degrau da perturbação produz resultados equivalentes aos encontrados nas variações das variáveis controladas na rotina operacional e que demandam a atuação manual da operação. Verifica-se aqui se o M_{MPC} com o modelo *H* e, portanto, com capacidade de rejeitar distúrbios, opera melhor que o M_{MPC} sem o modelo *H* para o

caso de um distúrbio constante. Figura 101, Figura 102, Figura 103 e Figura 104 expõem o comportamento do M_{MPC} quando sujeito a esses distúrbios de característica constante.

Figura 99 Resposta do controlador M_{MPC} a distúrbios constantes – TIC-23099.

Fonte: Autor.

Figura 100 Resposta do controlador M_{MPC} a distúrbios constantes – AIC-23001.

Fonte: Autor.

Figura 101 Resposta do controlador M_{MPC} a distúrbios constantes – PIC-23039.

Fonte: Autor.

Figura 102 Resposta do controlador M_{MPC} a distúrbios constantes – variáveis manipuladas.

Fonte: Autor.

Na Figura 103 é apresentado o gráfico com o critério IAE e suas diferenças percentuais.

Figura 103 Critério IAE do controlador M_{MPC} com e sem modelo H com distúrbios constantes.

Fonte: Autor.

7.4 ANÁLISE AMPLIADA DOS CONTROLADORES MPC COM E SEM MODELO H

Os controladores com e sem modelo H foram comparados através de uma varredura das perturbações injetadas nos três canais de perturbações não medidas, mantendo-se a o *set-point* constante. A varredura usou perturbações com as faixas das variâncias da Tabela 29. Essas faixas criaram 420 valores para cada canal de cada controlador.

Tabela 29 - Faixa das variâncias das perturbações injetadas nos três canais de perturbações não medidas de entrada.

Variável	TIC-23099	AIC-23001	PIC-23039
Valor Inicial	4	3	0.35
Passo	1	0.5	0.05
Valor Final	10	1.5	0.1

Fonte: Autor.

Esses limites foram obtidos com a Engenharia de Otimização, que analisou os sinais simulados resultantes das perturbações nas variáveis controladas.

As Figura 104 a 106 exibem as respostas do controlador M_{MPC} com e sem modelo de perturbação não medida.

Figura 104 – Resposta da TIC-23099 às perturbações com o controlador MPC com e sem modelo H .

Fonte: Autor.

Figura 105 – Resposta da AIC-23001 às perturbações com o controlador MPC com e sem modelo H .

Fonte: Autor.

Figura 106 – Resposta da PIC-23039 às perturbações com o controlador MPC com e sem modelo H .

Fonte: Autor.

A visualização da Figura 106 pode dificultar a percepção sobre a possibilidade de uma das execuções do M_{MPC} sem o modelo H ter ficado melhor. Para resolver essa questão, o comando *sum* do MATLAB, em conjunto com o operador relacional maior aplicado a todos os elementos dos vetores de resposta foi usado e não retornou resultados.

As médias e desvios padrão das três variáveis controladas são apresentadas na Tabela 30.

Tabela 30 - Médias e desvios-padrão dos resultados das simulações do controlador MPC com e sem H .

Variável	TIC-23099	AIC-23001	PIC-23039
IAE sem H			
Média	1459,35	13,86	6,00
Desvio Padrão	206,00	3,80	0,88
IAE com H			
Média	195,33	4,06	4,97
Desvio Padrão	34,99	0,57	0,69

Fonte: Autor.

7.5 CONCLUSÃO DA COMPARAÇÃO

As comparações feitas entre o MPC com um modelo das perturbações não medidas da planta e outro MPC que realiza esse tratamento de modo não integrador e genérico, mostram que há melhoria no desempenho do primeiro. A maior contribuição deste trabalho são os resultados motivadores para gerar modelos de perturbação de entradas não medidas na implementação do MPC. Além dessa contribuição, esta tese poderá motivar o desenvolvimento de controladores preditivos com ênfase na rejeição das perturbações na planta, melhorando o desempenho do processo controlado e diminuindo a sua variabilidade.

Este trabalho usou a ferramenta computacional MATLAB, viabilizando a reprodução das atuações e respostas da planta real em uma simulação com um modelo com um grau de aderência aceitável ao processo real, com a inserção no MPC de perturbações não medidas e de seus sinais de entrada. Outro aspecto relevante deste trabalho foi a utilização de dados reais de uma planta importante no cenário brasileiro e que carece de tratamento de seus distúrbios.

Neste projeto, conclui-se mediante análise, que a hipótese na qual esta tese se baseia é confirmada, isto é, o controlador MPC com modelo de perturbação mostrou-se com desempenho melhor, com relação ao controlador sem o conhecimento ou modelo da perturbação não medida.

Nesta tese, buscaram-se métodos alternativos aos convencionais para o problema de sintonia, conseguindo assim, os melhores parâmetros para o controlador MPC. A sintonia do controlador foi feita através do algoritmo genético multi-objetivo, conhecido como MOGA (*Multi-Objective Genetic Algorithm*) ou Algoritmo Genético Multi-Objetivo. O uso deste algoritmo propiciou obter um conjunto de parâmetros que satisfazem as restrições de projeto, tornando possível diminuir as incertezas ou influência da sintonia do controlador, que poderiam dificultar a análise comparativa. Não obstante, a otimização dos parâmetros de sintonia do MPC teve um impacto positivo na robustez e, conseqüentemente, no desempenho frente às variações impostas pelo processo.

A implementação futura do controle preditivo MPC em sistemas de geração de energia térmica (fornos industriais) sujeitos a perturbações não medidas, conforme os resultados obtidos nas simulações do controlador preditivo com modelo H , poderá propiciar um ganho proporcional à carga do equipamento. O resultado do IAE das comparações evidencia que o controle com modelo H tem melhor desempenho quando submetido a perturbações estocásticas, propiciando uma redução da variabilidade entre o *set-point* e as variáveis controladas, de no mínimo 1% a mais de eficiência com o uso do controlador M_{MPC} nos momentos em que a perturbação ocorre. No caso do processo PETROSIX®, se for considerado um período de ocorrência de 10% do dia (aproximadamente 144

minutos), esse ganho percentual na eficiência térmica global, no caso específico desse forno petroquímico, representa uma economia de US\$ 0,5 milhões por ano. No entanto, é meritório assinalar que as perturbações não medidas neste processo ocorrem com uma frequência maior (8 horas). O cálculo da eficiência térmica global pode ser aplicado a outros equipamentos térmicos, tais como caldeiras, unidades de cogeração e termoeletricas, sujeitos a distúrbios de natureza estocástica. Além dos aspectos econômicos destacados, mas não menos importante, está a diminuição nas emissões de gases e outros poluentes, que e podem ser nocivos ao meio-ambiente.

CAPÍTULO 8

CONCLUSÕES

O Controle Preditivo Multivariável tem se tornado cada vez mais presente nas soluções de controle e otimização de plantas com dinâmicas complexas, em que as variáveis controladas apresentam intensa interação entre si. A redução da variabilidade do processo e a otimização da produção através da operação da planta, dentro dos limites de projeto, são as principais vantagens do controlador MPC, o qual propicia uma operação mais próxima do ponto ótimo, transpondo as dificuldades resultantes de limitações operacionais, tais como restrições físicas de equipamentos ou limites relacionados com as operações inferenciais.

Todavia, existem dúvidas na comunidade que estuda ou aplica o MPC sobre as vantagens de se incorporar a funcionalidade de se usar um modelo para rejeitar perturbações não medidas (H). A dúvida é se é ou não vantajoso incorporar esse modelo na formulação do MPC, cuja criação demanda recursos de engenharia, de produção e de desenvolvimento e que aumenta o custo de sua implantação. Este trabalho visou diminuir essa dúvida.

As comparações realizadas entre um MPC com um modelo interno capaz de suportar as perturbações estimadas da planta e outro MPC que realiza esse tratamento de maneira não integradora e genérica mostram que há melhorias no desempenho do primeiro. A melhora de desempenho é invariável em um espectro de perturbações esperado pelo processo onde ele está inserido, confirmando a hipótese apresentada para o caso do forno industrial da SIX.

Durante o desenvolvimento da pesquisa bibliográfica sobre o tema central desta tese, constatou-se que até o presente momento não havia nenhum trabalho publicado referente à análise comparativa através de simulação ou teste experimental prático, entre controladores preditivos com e sem modelo de perturbação não medida. A utilização de dados reais de uma planta importante no cenário brasileiro e que carece de tratamento de distúrbios no atual controle de seu forno, pode trazer a ela benefícios econômicos e de segurança operacional.

Além destas contribuições, esta tese tem o potencial de motivar o desenvolvimento de novos controladores preditivos, com maiores recursos para o usuário para o tratamento e rejeição das perturbações na planta, melhorando processos e reduzindo sua variabilidade.

8.1 SUGESTÕES PARA TRABALHOS FUTUROS

Com o objetivo de propor a continuidade da pesquisa científica, esta tese deixa em aberto oportunidades para as seguintes iniciativas futuras:

- Prova matemática dos resultados deste trabalho para o caso genérico, ou seja, para qualquer processo industrial;
 - Criação nas atuais soluções de controle preditivo de maiores facilidades para o usuário para a inserção e sintonia dos modelos de perturbação de maneira amigável;
 - Implantação do M_{MPC} no forno da SIX ou em outro processo; e
 - Implantação ou ressintonia de MPCs em uso com resultados de sintonias provenientes do método MOGA;
 - Utilizar a otimização multiobjetivo (MOGA) para identificação e validação de modelos matemático e realizar análise comparativa entre o modelo identificado pelo algoritmo multiobjetivo e outros métodos de identificação;
 - Testar a adaptação da variância da perturbação não medida, por exemplo, com a utilização de um filtro de Kalman, ajustando a variância para o controlador ou outras abordagens de adaptação.
-

REFERÊNCIAS BIBLIOGRÁFICAS

- ABB. **Process Improvement Packages Multivariable Control for the Process Industries – 3d MPC™**. [s.l: s.n.].
- ABOLO, A. J. N. et al. Geochemical Characterization and Mineralogy of Babouri-Figuil Oil Shale, North-Cameroon. **Journal of Surface Engineered Materials and Advanced Technology**, v. 04, n. 06, p. 359–368, 2014.
- AGUIRRE, L. A. **Introdução à identificação de sistemas: Técnicas lineares e não-lineares aplicadas a sistemas reais**. 2º ed. ed. Belo Horizonte: UFMG, 2004.
- AGUIRRE, L. A. **Introdução à Identificação de Sistemas. Técnicas lineares e Não lineares: Teoria e Aplicação**. 4º Edição ed. Belo Horizonte: Editora Universidade Federal de Minas Gerais, 2014.
- AGUIRRE, L. A. Introdução à identificação de sistemas. Técnicas lineares e não lineares: Teoria e aplicação. n. May, p. 776, 2015.
- ÅKESSON, I. N. MPC in Column control. **Control and Application - ABB**, v. 1, p. 1–8, 2002.
- AMRIT, R. et al. Platform for Advanced Control and Estimation (PACE): Shell's and Yokogawa's next generation Advanced Process Control technology. **IFAC-PapersOnLine**, v. 28, n. 8, p. 1–5, 2015.
- ANSARPANAHI, S.; NOOR, S. B. ; MARHABAN, M. H. Stability Study of Model Predictive Control in Presence of Undesirable Factors. **Journal of Applied Sciences**, v. 8, n. 20, p. 3683–3689, 2008.
- ANTONIOU, A. **Digital Signal Processing: Signals, Systems, and Filters**. First Edit ed. British Columbia - Canada: McGraw-Hill Science/Engineering/Math, 2006.
- ARAUJO, R. de B. **CONTROLADORES PREDITIVOS FILTRADOS UTILIZANDO OTIMIZAÇÃO MULTIOBJETIVO PARA GARANTIR OFFSET-FREE E ROBUSTEZ**. 2017. Universidade Federal de Florianópolis, 2017.
- ÅSTRÖM, K. J.; HÄGGLUND, T. **PID Controllers - Theory, Design, and Tuning (2nd Edition)**. Second Edi ed. USA: Instrument Society of America, 1995.
- AZEVEDO, P. R. M. de. **Introdução à estatística**. 1º Edição ed. Natal RN: Universidade Federal do Rio Grande do Norte, 2016.
- BADGWELL, T. A. Estimation of MPC The State of Model Predictive Control. **Linear algebra and its applications**, v. 432, p. 670–677, 2010.
- BATISTA, G. E. de A. P. A. **Pré-processamento de Dados em Aprendizado de Máquina Supervisionado**. 2003. 2003. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-06102003-160219/publico/TeseDoutorado.pdf>>.
- BECCUTI, A. G.; GEYER, T.; MORARI, M. Temporal lagrangian decomposition of model predictive control for hybrid systems. **Proceedings of the IEEE Conference on Decision and Control**, v. 3, p. 2509–2514, 2004.
- BEMPORAD, A. et al. The explicit linear quadratic regulator for constrained systems. **Automatica**, v. 38, n. 1, p. 3–20, 2002.
- BEMPORAD, A.; MORARI, M.; RICKER, N. L. **Model Predictive Control Toolbox™ Getting Started Guide**. R2015B. ed. NATICK, MA 01760-2098: MathWorks, 2015.
- BEMPORAD, A.; RICKER, N. L.; MORARI, M. **Model Predictive Control Toolbox™ Getting**

-
- Started Guide How to Contact MathWorks.** First Edit ed. Natick, Massachusetts, Estados Unidos: The Mathworks, Inc., 2019.
- BEMPORAD, A.; RICKER, N. L.; OWEN, J. G. Model Predictive Control - New tools for design and evaluation. **American Control Conference**, v. 1, p. 5622–5627, 2004.
- BERNSTEIN, D. S. Robust Static and Dynamic Output-Feedback Stabilization: Deterministic and Stochastic Perspectives. **IEEE Transactions on Automatic Control**, v. 32, n. 12, p. 1076–1084, 1987.
- BLEVINS, T. Wireless MPC Application for Dividing Wall Column Control. (ISA, Ed.) In: Houston, Texas USA. **Anais...** Houston, Texas USA: ISA - Setting The Standard for Automation, 2015.
- BRAVO, C. O. A.; NORMEY-RICO, J. E. Controle de plantas não-lineares utilizando controle preditivo linear baseado em modelos locais. **Revista Controle & Automação**, v. 20, n. 4, p. 17, 2009.
- BROOKNER, E. **Tracking and Kalman Filtering Made Easy.** First Edit ed. Sudbury, MA: John Wiley & Sons, Inc., 1998. v. 1
- BUENO, F. **Métodos Heurísticos - Teoria e Implementações.** [s.l: s.n.]. Disponível em: <<https://sites.google.com/site/tecprojalgoritmos/tecnicas-de-projetos/heuristicas>>.
- CAMACHO, E. F.; BORDONS, C. Control predictivo: pasado, presente y futuro. **Revista Iberoamericana e Informática Industrial**, v. V.1, n. n.3, p. 5–28, 2004.
- CAMACHO, E. F.; BORDONS, C. **Model Predictive Control.** 2º Edition ed. Seville: Springer, 2007.
- CAMOLESI, V. J.; MORO, L. F. L.; ZANIN, A. C. Implantação de um Otimizador em Tempo Real (RTO) no Conversor de uma Unidade de Craqueamento Catalítico. **Controle y Automacao**, v. 19, n. 2, p. 128–137, 2008.
- CAMPHER, A. H. **A Systematic Approach to Model Predictive Controller Constraint Handling : Rigorous Geometric Methods Master of Engineering (Control Engineering) A Systematic Approach to Model Predictive Controller Constraint Handling : Rigorous Geometric Methods.** 2011. University of Pretoria Pretoria, 2011.
- CAMPOS, M. C. M. M.; TEIXEIRA, H. C. G. **Controles Típicos de Equipamentos e Processos Industriais** São Paulo Editora Edgard Blucher Ltda, , 2006. .
- CANG, D. B. **Modern Predictive Control.** First Edit ed. New Jersey: Taylor and Francis Group, LLC, 2010.
- CAPRON, B. O. **LMI-based Model Predictive Control of uncertain stable and unstable systems based on a realigned state space representation.** 2014. Universidade de São Paulo, 2014.
- CASTELIJNS, N. **Honeywell APC-Advanced Control, Optimization, and Monitoring.** [s.l: s.n.].
- CENSOR, Y. Pareto Optimality in Multiobjective Problems. **Appl. Math. Optimiz.**, v. 4, p. 41–59, 1977.
- CLARKE D, MOHTADI C, T. P. Generalized Predictive Control - Part II Extensions and Interpretations. p. 150–153, 1987.
- CLARKE, D. W. W.; MOHTADI, C.; TUFFS, P. S. S. Generalized Predictive Control - Part II Extensions and interpretations. **Automatica**, v. 23, n. 2, p. 137–148, mar. 1987. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0005109887900872>>. Acesso em: 23 ago. 2013.
- CORRÊA, S. J. **Parque Industrial de Refino No brasil Características Atuais e Perspectivas Futuras.** 2009. 2 Universidade Federal do Rio de Janeiro - UFRJ, 2009.
- COULOURIS, G. et al. **Sistemas Distribuídos Conceitos e Projetos.** 5º edição ed. Porto Alegre -
-

Brasil: Bookman, 2013.

CRAWFORD, P. M.; KILLEN, J. C. **New Challenges and Directions in Oil Shale**. [s.l: s.n.]

CUTLER, A. et al. The syllable's differing role in the segmentation of French and English. **Journal of Memory and Language**, v. 25, n. 4, p. 385–400, 1983.

CUTLER, C. R.; MORSHEDI, A.; HAYDEL, J. An industrial perspective on advanced control. In: AICHE Annual Meeting. **AIChE Journal**, v. 1, p. 3210–3217, 1983.

DARBY, M. L.; NIKOLAOU, M. MPC: Current practice and challenges. **Control Engineering Practice**, v. 20, n. 4, p. 328–342, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.conengprac.2011.12.004>>.

DE MELO, L. P. **Transferência de calor em um processo de pirólise de partículas de xisto de um reator industrial**. 2013. Universidade, 2013.

DECHECHI, E. C. **Controle avançado preditivo adaptativo , “DMC Multivariável Adaptativo”**. 1998. Universidade de Campinas, 1998.

EMERSON PROCESS MANAGEMENT. **DeltaV Predict and DeltaV PredictPro**. [s.l: s.n.].

ENGELBERG, S. **A Mathematical Introduction to Control Theory**. First Edit ed. Jerusalem - Israel: Imperial College Press -British Library, 2005.

FARLANE, R. C.; RIVERA, D. E. Identification of Distillation Systems. Practical Distillation Control. **IEE Colloquium (Digest)**, n. 23, p. 96–139, 1992.

FELÍCIO, L. C. **Modelagem da Dinâmica de Sistemas e Estudo da Resposta**. Segunda Ed ed. São Carlos - São Paulo: Rima Editora, 2010.

FILHO, J. D. **ESTUDO DE VIABILIDADE DE LAVRA COM USO DE MINERADORES DO SUL – PR** . 2017. Universidade Federal de Ouro Preto, 2017.

FRANK, M.; WOLFE, P. An algorithm for quadratic programming. **Naval Research Logistics Quarterly**, v. 3, p. 95–110, 1956.

GARCIA, C. **Identificação de Sistemas. Notas de Aula**São Paulo - SPUniversidade de São Paulo, , 2005. .

GARCIA, C. E.; MORSHEDI, A. M. Quadratic programming solution of dynamic matrix control (QDMC). **Chemical Engineering Communications**, v. 46, n. 1–3, p. 73–87, 1986.

GARCIA, C. E.; PRETT, D. M.; MORARI, M. Model Predictive Control : Theory and Practice a Survey. **Automatica**, v. 25, n. 3, p. 335–338, 1989. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0005109889900022>>.

GEVERS, M. A Personal View On the Development Of Sytem Identification. **13º IFAC Symposium on System Identification (2003)IFAC Sytem Identification**, v. 1, p. 773–784, 2003.

GOUVÊA, T. De; ODLOAK, D. Rossmpc: A new way of representing and analysing predictive controllers. **Chemical Engineering Research and Design**, v. 75, n. 7, p. 693–708, 1997.

HAYKIN, S. **Kalman Filtering And Neural Networks**. Third Edit ed. Ontario-Canada: JOHN WILEY & SONS, INC., 2001.

HINOJOSA, A. I.; CAPRON; ODLOAK, D. REALIGNED MODEL PREDICTIVE CONTROL OF A PROPYLENE DISTILLATION COLUMN. **BRAZILIAN JOURNAL OF CHEMICAL ENGINEERING**, v. 33, n. 01, p. 191–202, 2016.

HORN, D. Model Predictive Control (MPC) Pavilion8. **Rockwell Advances in Industrial Control**, v. 2, p. 15–34, 2009.

I. M. ROZENBERG. **O Sistema Internacional de Unidades - SI**. 3º Edição ed. São Paulo - SP: Instituto Mauá de Tecnologia, 2006.

-
- ISERMANN, R.; MÜNCHHOF, M. **Identification of Dynamic Systems**. Heidelberg Dordrecht London New York: Springer, 2011.
- JIANG, S. et al. Extreme enrichment of polymetallic Ni – Mo – PGE – Au in lower Cambrian black shales of South China : An Os isotope and PGE geochemical investigation. **ScienceDirect**, v. 254, p. 217–228, 2007.
- JOHANSSON, A. **Functional Enhancements of Multivariable Predictive Controller Predictive Controller** . 2002. University of Technology Lulea, 2002.
- JONES, D. S. J. S.; PUJADÓ, P. R. **Handbook of Petroleum Processing**. First Edit ed. USA: Springerr, 2006.
- K. DEB. Multi-Objective Optimization Using Evolutionary Algorithms. **John Wiley & Sons**, 2001.
- KALAFATIS, A.; CAMPBELL, J. Next Generation MPC – Where is Technology Headed? AspenTech Product Management. (A. P. Management, Ed.) In: Technology Predictive Control, California, U.S.A. **Anais...** California, U.S.A: ASpenTech, 2017.
- KALMAN, R. E. A New Approach to Linear Filtering and Prediction Problems. **Journal of Basic Engineering - Transaction of the ASME**, p. 33–45, 1960.
- KALMAN, R. E.; ENGIAR, T. S.; BUEY, R. S. **Fundamental Study Of Adapptive Control Systems**. [s.l: s.n.].
- KANO, M.; OGAWA, M. The state of art in advanced process control in Japan. **IFAC symposium ADCHEM**, p. 10–25, 2009.
- KEYSER; IONESCU, R.; C.M. The Disturbance Model in Model Based Predictive Control. **Automatic Control and Informatics**, v. pp.14-20, p. 446–451, 2004.
- KIM, Y.; BANG, H. Introduction to Kalman Filter and Its Applications. **Korea Advanced Institute of Science and Technology - Daejeon - Soth Korea**, v. 1, n. September, p. 1–18, 2019.
- KLERK, E.; GRAIG, I. K. MULTIVARIBLE AND CLOSED-LOOP SYTEM IDENTIFICATION OF PLANTS UNDER MODEL PREDICTIVE CONTROL. **13º IFAC Symposium on System Identification (2003)**, v. II, p. 431–436, 2003.
- KOTHARE, M. V.; BALAKRISHNAN, V.; MORARI, M. Robust constrained model predictive control using linear matrix inequalities. **Automatica**, v. 32, n. 10, p. 1361–1379, 1996.
- LARROTA, F. N. L.; BOMBARDELLI, C.; GARCIA, C. A influência da correlação cruzada dos sinais de excitação na identificação multivariável. **Anais do XX Congresso Brasileiro de Automática**, n. 2012, p. 8, 2014.
- LEBLANC STEVEN, COUGHANOWR, D. Process Systems Analysis and Control. In: MCGRAW-HILL (Ed.). **Process Systems Identification**. Third Edit ed. Boston: Leblanc, 2009. p. 391–630.
- LEE, J. h.; MORARI, M.; GARCIA, C. E. State-space interpretation of model predictive control. **Automatica**, v. 30, n. 4, p. 707–717, 1994.
- LEE, J. H.; YU, Z. Worst-case Formulations of Model Predictive Control for Systems with Bounded Parameters. **Automatica**, v. 33, n. 3, p. 763–781, 1997.
- LEE, J. H.; YU, Z. H. Tuning of model predictive controllers for robust performance. **Computers and Chemical Engineering**, v. 18, n. 1, p. 15–37, 1994.
- LJUNG, L. **System Identification Theory for the User**. First Edit ed. New Jersey: Prentice Hall, Inc., 1999. v. 25
- LJUNG, L. **System Identification Toolbox For Use With MATLAB – User Guide Version 6**. Version 6 ed. Natick - Massachusetts - Estados Unidos: The Mathworks, Inc., 2002.
- MACHADO, V. C. **Planejamento de Perturbações para a Identificação de Modelos Dinâmicos**. 2004. Universidade Federal do Rio Grande do Sul, 2004.
-

-
- MAGNI, L. et al. **Nonlinear Model Predictive Control-Lecture Notes In Control And Information Sciences**. First Edit ed. Verlag Berlin Heidelberg: Springer, 2009.
- MALINOSKI, F. **Caracterização do Rejeito Finos de Xisto e Subproduto do Calcário de Xisto do Processo PETROSIX®**. 2012. Universidade Estadual de Ponta Grossa, 2012.
- MANSOUR, T. **PID Control, Implementation and Tuning**. Intech ed. Croatia: Ivana Lorkovic, 2012.
- MANUELA, E.; FERNANDES, G. P. **Estatística Aplicada**. 1º Edição ed. Braga, Portugal: Universidade do Minho, Braga, 1999.
- MARCHIONNA, A. **Model Identification Process : From data collection to calibrated, empirical, dynamic, linear models**. U.S.A: Spentech, , 2017. .
- MARLIN, T. **Process control: Designing processes and control systems for dynamic performance**. Second Ed ed. Houston - USA: McGraw-Hill Education, 1996. v. 1
- MATHWORKS. **MPC Toolbox Versão 6.2**. Natick, Massachusetts, Estados Unidos. The MathWorks, Inc, , 2018a. .
- MATHWORKS. **Global Optimization Toolbox Versão 8.2**. Natick, Massachusetts, Estados Unidos. The MathWorks, Inc., , 2018b. .
- MATHWORKS. **Matlab Documentation**. [s.l: s.n.]. Disponível em: <<https://www.mathworks.com/help/releases/R2018b/mpc/ug/qp-solver.html>>. Acesso em 20/06/2019>.
- MATHWORKS, T. **MATLAB Release 2018b**. [s.l: s.n.].
- MAYNE, D. Q.; MICHALSKA, H. Robust Receding Horizon Control of Constrained Nonlinear Systems. **IEEE Transactions on Automatic Control**, v. 38, n. 1, p. 1623–1633, 1993.
- MOHINDER, S. G.; ANGUS, P. A. **Kalman Filtering: Theory and Practice with MATLAB**. Mohinder, ed. New Jersey - U.S.A: A JOHN WILEY & SONS, INC., PUBLICATION, 2008.
- MORO, L. F. L. SICON-Uma Solução Cliente Servidor Para o Controle Avançado. **IV Congresso Petrobras de Informática e Telecomunicações - INFTEL**, v. 1, p. 1–10, 1997.
- MORO, L. F. L.; CAMOLESI, V. J.; ZANIN, A. C. Implantação De Um Otimizador Em Tempo Real (Rto) No Conversor De Uma Unidade De Craqueamento Catalítico. **Revista Controle & Automação**, v. 19, n. 2, p. 128–137, 2008.
- MORETTIN, L. G. **Estatística Básica: Probabilidade Volume 1**. 1º Edição ed. São Paulo - SP: Makron Books, 1999.
- MOTA, É. P. **QUEDA DE PRESSÃO EM UM LEITO DE PARTÍCULAS DE XISTO: AVALIAÇÃO DE MODELOS PARA DISTRIBUIÇÃO GRANULOMÉTRICA E DIÂMETROS MÉDIOS EQUIVALENTES, ESTUDO DO EFEITO DA ALTURA DO LEITO E AVALIAÇÃO DE MODELOS PARA PREDIÇÃO DA QUESA DE PRESSÃO**. 2009. 1 Universidade Federal do Paraná, 2009. Disponível em: <<http://dx.doi.org/10.1016/B978-0-12-849873-6.00001-7>><http://saber.ucv.ve/ojs/index.php/rev_venes/article/view/1112>.
- MOUDGALYA, K. **Digital Control**. First Edit ed. England: John Wiley & Sons Ltd, The Atrium, Southern Gate, Chichester, 2007.
- MUSKE, K. R.; RAWLINGS, J. B. Model Predictive Control with Linear Models. **AIChE Journal**, v. 39, p. 262–267, 1993.
- NICOLINI, J. **Avaliação do impacto ambiental de solos de área experimental da Embrapa Clima Temperado onde foram aplicados subprodutos do xisto da Petrobras-SIX como condicionadores de solo**. 2011. Universidade Federal do Paraná, 2011.
- NORMEY-RICO, J. E.; CAMACHO, E. F. **Controle of Dead-time Process**. First Edit ed. Sevilla
-

Spain: Springer Science, 2007.

- NUNES, G. **Desenvolvimento de Sistema Especialista Para Inferência da Qualidade da Carga e Otimização de Reator de Pirólise de Folhelho Pirobetuminoso**. 2013. Universidade Federal do Paraná, 2013.
- OPPENHEIM, A. V.; SCHAFER, R. W. **Discrete-Time Signal Processing**. Second edi ed. New Jersey - U.S.A: Prentice Hall, 1998.
- PANNOCCHIA, G. et al. MULTIVARIABLE SUBSPACE IDENTIFICATION AND PREDICTIVE CONTROL OF A HEAT-INTEGRATED. **International Symposium on Advanced Control of Chemical Processes -ADCHEM 2006**, n. 3, p. 421–426, 2006.
- PANNOCCHIA, G.; RAWLINGS, J. B. Robustness of MPC and Disturbance Models for Multivariable Ill-Conditioned Processes. **Chemical Engineering**, p. 1–26, 2001.
- PATIL, N. S.; SHARMA, S. N. A prediction theory for a coloured noise-driven stochastic differential system. **Systems Science and Control Engineering**, v. 2, n. 1, p. 342–350, 2014.
- PERISSÉ, J. B. **Evolução Do Refino De Petróleo No Brasil**. 2007. Univsersidade do Estado do Rio de Janeiro UERJ, 2007.
- PINHEIRO, T. C. F. **Controle MPC multivariável com restrições usando funções de Laguerre**. 2018. Universidade Federal do Pará, 2018. Disponível em: <http://ppgee.propesp.ufpa.br/ARQUIVOS/dissertacoes/DM_10_2018_Tarcísio_Carlos_Farias_Pinheiro.pdf>.
- PINTO, J. PACE – Modelo Coluna de Destilação. (Yokogawa Eletric Corporation, Ed.) In: Innovating Tomorrow, Brasil. **Anais...** Brasil: Yokogawa, 2016.
- PORFÍRIO, C. R. **Implantação de um controlador multimodelos em uma coluna depropanizadora industrial**. 2001. Universidade de São Paulo, 2001.
- PORFÍRIO, C. R.; NETO, E. A.; ODLOAK, D. Multi-model predictive control of an industrial C3/C4 splitter. **Control Engineering Practice**, v. 11, n. 7, p. 765–779, 2003.
- PRETT, D. M.; RAMAKER, B. L.; CUTLER, C. R. **United States Patent TO 1C6**. USA - Houston: 19, 1979. .
- PROPOL, A. I. Use if Linear Programming methods for synthesizing sampled data automatic systems. **Automation an Remote Control**, v. 24, p. 837–844, 1963.
- QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control Engineering Praticce**, v. 11, p. 733–764, 2003.
- RALHAN, S.; BADGWELL, T. A. Robust control of stable linear systems with continuous uncertainty. **Computers and Chemical Engineering**, v. 24, n. 11, p. 2533–2544, 2000.
- RIBAS, L. **INFLUÊNCIA DO PROCESSO DE PIROLÍSE SOBRE AS CAMADAS DE FOLHELHO PIROBETUMINOSO DE SÃO MATEUS DO SUL– PR**. 2012. Universidade Federal do Paraná, 2012.
- RICHALET et al. Model predictive heuristic control. Applications to industrial processes. **Automatica**, v. 14, n. 5, p. 413–428, 1978.
- RICHALET, J. Industrial applications of model based predictive control. **Automatica**, v. 29, n. 5, p. 1251–1274, 1993.
- RICHALET, J.; O'DONOVAN, D. **Predictive Functional Control**. First Edit ed. Verlag - London: Springer, 2009.
- RIVERA, D. E.; FLORES, M. E. Beyond Step Testing and Process Reaction Curves: Introducing Meaningful System Identification Concepts in the Undergraduate Chemical Engineering Curriculum. **IFAC Proceedings Volumes**, v. 33, n. 15, p. 815–820, 2000.

-
- ROCKWELL. **Model predictive control Rockwell Automation - Pavilion8Advances in Industrial Control**. [s.l: s.n.].
- ROCKWELL AUTOMATION. **L10 - PlantPAx ® MPC : Optimization in the Logix Controller for Easy Deployment Agenda. What is Model Predictive Control. Lab Overview**. U.S.A Rockwell Automation, , 2015. .
- RODRIGUES, M. A.; ODLOAK, D. Robust Stable MPC via Dynamic Output Feedback. **IFAC Proceedings Volumes**, v. 33, n. 10, p. 809–814, 2000. Disponível em: <[http://dx.doi.org/10.1016/S1474-6670\(17\)38639-1](http://dx.doi.org/10.1016/S1474-6670(17)38639-1)>.
- RODRIGUES, M. A.; ODLOAK, D. Including model uncertainty in the model predictive control with output feedback. **Brazilian Journal of Chemical Engineering**, v. 19, n. 4, p. 475–482, 2001.
- ROFFEL, B.; BETLEM, B. H. **Advanced Practical Process Control**. First Edit ed. The Netherlands: Springer, 2004.
- ROFFEL, B.; BETLEM, B. H. **Process dynamics and control: modeling for control and prediction**. First Edit ed. England: John Wiley & Sons, Ltd, 2006.
- SANTORO, B. F. **Development of a stochastic model predictive controller for processes in the chemical industry**. 2015. Universidade de São Paulo, 2015.
- SANTOS, L. C. dos. **Gestão de recursos e reservas para aumento do aproveitamento do folhelho pirotetuminoso e aumento da recuperação de sua matéria orgânica na forma dos derivados óleo e gás**. 2009. Universidade de São Paulo, 2009.
- SARGAR, S. K.; SONDKAR, S. Y.; PROPERTIES, A. C. Study and Implementation of Advanced Control and Optimization for Ethylene Furnace using DeltaV System. **Long Paper Int. J. on Recent Trends in Engineering and Technology**, v. 9, n. 1, p. 39–45, 2013.
- SCOKAERT, P. O. M.; MAYNE, D. Q. Min–Max Feedback Model Predictive Control for Constrained Linear Systems. v. 43, n. 8, p. 1136–1142, 1998.
- SEBORG, D. E. et al. **Process Dynamics and Control**. p. 5–596, 2011.
- SECCHI, A. R. Modelagem e Simulação de Processos PARTE I: Introdução. In: SECCHI, A. R. (Ed.). **UFRGS**. 1º Edição ed. Porto Alegre - Brasil: Departamento de Engenharia Química Escola de Engenharia Universidade Federal do Rio Grande do Sul -UFRGS, 1995. p. 199.
- SHANNON, C. E. A Mathematical Theory of Communication. **Bell System Technical Journal**, v. 27, n. April 1928, p. 379- 423, 623-656, 1948.
- SILVA, M. G. da. **PROJETO DE CONTROLADOR PREDITIVO: ABORDAGEM POLINOMIAL E NO ESPAÇO DE ESTADOS**. 2018. 1 Universidade Federal do Pará, 2018.
- SILVEIRA, A. da S. **CONTRIBUIÇÕES AO CONTROLE DE VARIÂNCIA MÍNIMA GENERALIZADO: ABORDAGEM DE PROJETO NO ESPAÇO DE ESTADOS**. 2012. 1 Universidade Federal de Santa Catarina, 2012.
- SILVEIRA, R. P. et al. Systematic Approaches for PI SystemTM Data Compression Tuning. **8th IFAC Symposium on Advanced Control of Chemical Processes, Singapore, July 10-13**, v. 8, n. PART 1, p. 309–313, 2012.
- SÖDERSTRÖM, T.; STOICA. **System identification - Prentice-Hall International series in Systems and Control Engineering**. First ed. Vienna: Technical University Vienna, 1989. v. V
- SONTAG, E. D. **Mathematical Control Theory Deterministic Finite Dimensional Systems**. Second Edi ed. [s.l: s.n.]
- THOMA, E. M.; WYNER, A. **Foundations of Adaptive Control**. First edit ed. California - USA: M. Thoma A. Wyner, 1991.
-

-
- TINSLEY, H. E. A.; BROWN, S. D. **Multivariate Statistics and Mathematical Modeling**. First Edit ed. Florida USA: Elsevier Science & Technology Books, 2000.
- TULLEKEN, H. J. A. F. Generalized binary noise test-signal concept for improved identification-experiment design. **Automatica**, v. 26, n. 1, p. 37–49, 1990.
- VAN WOENSEL, T.; WUYTS, B.; VANDAELE, N. Validating state-dependent queueing models for uninterrupted traffic flows using simulation. **4or**, v. 4, n. 2, p. 159–174, 2006.
- VON WISSEL, D. et al. Linking model predictive control (MPC) and system simulation tools to support automotive system architecture choices. **8th European Congress on Embedded Real Time Software and Powertrain Systems, Toulouse, France**, v. 1, n. 1, p. 1–10, 2016.
- WELCH, G.; BISHOP, G. An Introduction to the Kalman Filter. In: GARY BISHOP; GREG WELCH (Ed.). **Kalman Filter - SIGGRAPH 2001**. First Edit ed. North Carolina - U.S.A: University of North Carolina at Chapel Hill, 2001. 1p. 1–81.
- XI, Y.-G.; LI, D.-W.; LIN, S. Model Predictive Control-Status and Challenges. **Acta Automatica Sinica**, v. 39, n. 3, p. 222–236, 2014. Disponível em: <[http://dx.doi.org/10.1016/S1874-1029\(13\)60024-5](http://dx.doi.org/10.1016/S1874-1029(13)60024-5)>.
- XU, F.; HUANG, B.; AKANDE, S. Performance assessment of model predictive control for variability and constraint tuning. **Industrial and Engineering Chemistry Research**, v. 46, n. 4, p. 1208–1219, 2007.
- YOKOGAWA ELECTRIC CORPORATION. **General Specifications Exasmoc _DCS Yokogawa**. [s.l: s.n.].
- YOKOGAWA ELECTRIC CORPORATION. **General Specifications for : Integrated Production Control System CENTUM VP System**. [s.l: s.n.].
- ZAKHAROV, A. V; BOSMAN, H. S.; JA, S. Two-Phase Model Predictive Control and Its Application to the Tennessee Eastman Process. **Industrial & Engineering Chemistry Research**, p. 2–14, 2013.
- ZELANY, M. A concept of compromise solutions and the method of the displaced ideal. **Computers & Operations Research**, v. 1, n. 3–4, p. 479–496, 1974.
- ZELLNER, A.; THEIL, H. THREE-STAGE LEAST SQUARES: SIMULTANEOUS ESTIMATION OF SIMULTANEOUS EQUATIONS. **Econometrica**, v. 30–1, n. 1, p. 1–25, 1962.
- ZHAN, R.; WAN, J. Neural network-aided adaptive unscented Kalman filter for nonlinear state estimation. **IEEE Signal Processing Letters**, v. 13, n. 7, p. 445–448, 2006.
- ZHENG, T. **Model predictive control**. first edit ed. Janeza Trdine - Croatia: Tao ZHENG, 2010. v. 197
- ZHU, Y. **Multivariable System Identification For Process Control**. Yucai Zhu ed. Eindhoven: Elsevier Science & Technology Books, 2001.
- ZHU, Y. et al. **System Parameter Identification**. Third Edit ed. U.S.A: Elsevier Inc. All, 2013.
- ZHU, Y.; BUTOYI, F. Case studies on closed-loop identification for MPC. **Control Engineering Practice**, v. 10, n. 4, p. 403–417, 2002.
-

Apêndice A

A.I - CRIAÇÃO DO CONTROLADOR MPC COM E SEM MODELO DE PERTURBAÇÃO

Para o desenvolvimento do controlador preditivo M_{MPC} , utilizou-se a ferramenta de engenharia MATLAB™. Esta ferramenta possibilitou desenvolver o controle preditivo M_{MPC} pela utilização do conjunto de pacotes que são: Model Predictive Control Toolbox, Optimization Toolbox, Global Optimization Toolbox, Control Toolbox, Simulink e o Signal Processing Toolbox (MATHWORKS, 2019b). A estrutura do modelo do M_{MPC} foi projetada neste software, conforme apresentado na Figura 83 do Capítulo 6. Todas as simulações foram executadas no sistema operacional Microsoft Windows® 7 Professional, de 2009, em um microprocessador Intel® Core™ i5-7200U, com duas CPUs rodando a 2.5 e 2.6 GHz e 8 GB de RAM.

A.II - CRIAÇÃO E IDENTIFICAÇÃO DO MODELO DA PLANTA

```

Function model = IdentifyPlant(plant)

% Identificação ARMAX de segunda ordem
ny = 3;
nu = 4;
na = 2*ones(ny, ny);
nb = 2*ones(ny, nu);
nc = [3; 3; 3];
nk = 1*ones(ny, nu);
model = armax(plant, [na nb nc nk]);
model.TimeUnit = 'minutes';

% Ampliação do modelo para conter os resíduos
model = ss(model, 'augmented');

% Nomeação das variáveis
model.OutputName = {'TIC-23099'; 'AIC-23001'; 'PIC-23039'};
model.InputName = {'FIC-23027.SP'; 'FIC-23028.SP'; 'FIC-23025.SP'; ...
    'FIC-23003'; 'UD1'; 'UD2'; 'UD3'};
model.OutputUnit = {'C'; '% O2'; 'bar'};
model.InputUnit = {'m3/h'; 'm3/h'; 'm3/h'; 'm3/h'; 'UD'; 'UD'; 'UD'};

% Configuração dos sinais do MPC
model = setmpcsignals(model, 'mv', 1:3, 'md', 4, 'ud', 5:7, 'mo', 1:3);

function [plant, nominal] = DefinePlant()

% Leitura dos dados coletados
data = readtable('FurnaceDataUpd.xlsx');
values = data.Variables;

% Escolha dos dados gerados durante a aplicação do PRBS
y = values(26:535, 5:7);
u = values(26:535, 1:4);

nominal.y = mean(y);
nominal.u = mean(u);

% Criação do objeto com os dados coletados da planta
Ts = 1;
plant = iddata(y, u, Ts);
plant = detrend(plant);
plant.TimeUnit = 'minutes';

% Nomeação das variáveis
plant.OutputName = {'TIC-23099'; 'AIC-23001'; 'PIC-23039'};

```

```
plant.InputName = {'FIC-23027.SP'; 'FIC-23028.SP'; 'FIC-23025.SP'; ...  
    'FIC-23003'};  
plant.OutputUnit = {'C'; '% O2'; 'bar'};  
plant.InputUnit = {'m3/h'; 'm3/h'; 'm3/h'; 'm3/h'};
```

A.III - CRIAÇÃO DAS REFERÊNCIAS

```
function r = GenerateReferences(nominal, T, stepMode)
```

```
% Criação das referência
```

```
r = repmat(nominal, T, 1);
```

```
if stepMode
```

```
    r(150:360, :) = r(150:360, :) + [15 0 0];
```

```
    r(50:100, :) = r(50:100, :) + [15 0 0];
```

```
    r(150:200, :) = r(150:200, :) + [15 0 0];
```

```
    r(250:360, :) = r(250:360, :) + [15 0 0];
```

```
end
```

A.IV - SIMULAÇÃO DA PLANTA COM PERTURBAÇÃO NÃO MEDIDA DE ENTRADA COM MODELO H

```
% Preparação do ambiente
clc
clear variables
close all
mpcverbosity off;

% Leia os dados coletados para o forno
[plant, nominal] = DefinePlant;

% Identifique o modelo do forno
model = IdentifyPlant(plant);

Ts = 1;
ctrl = CreateMPC(model, Ts, nominal);

% Preparação para a simulação
T = 720;
opt = mpcsimopt(ctrl);

% Criação de distúrbios constantes proporcionais às faixas das variáveis de saída
T_start = 30;
T_to_finish = T - T_start;

% disturbance = [repmat([0 0 0], T_start, 1); repmat([6 -1 -0.25], T_to_finish, 1)];
disturbance = [zeros(T_start, 3); [4 1 0.5].*randn(T_to_finish, 3)];

opt.UnmeasuredDisturbance = disturbance;
opt.Model = ctrl.Model.Plant;

% Valor estático da perturbação medida
v = 144.4543;

% Criação da referência (média das controladas)
r = GenerateReferences(nominal.y, T, false);

% Simulação do controlador e da planta externa com o
% modelo de perturbação de ganho unitário
rng default
ctrl.Model.Disturbance = ss(eye(3));
[y, t, u] = sim(ctrl, T, r, v, opt);

% Apresente os IAEs
IAE = sum(abs(r - y));
fprintf('IAEs do MPC com H: %8.4f %8.4f %8.4f\n', IAE)

save r r
save T T
```

```
save ys y
save us u
```

```
PlotMPCResults
```

A.V - SIMULAÇÃO DA PLANTA COM PERTURBAÇÃO NÃO MEDIDA

```
% Executa o controlador em malha aberta para descobrir
% os valores dos estados iniciais usando o mpcmove
% Limpe as variáveis e as plotagens
clear variables
clear global
close all
clc
global mpcCh
CreateModel();
DefineInitialStates();
% Especifique as opções de simulação
options = mpcsimopt();
options.RefLookAhead = 'off';
options.MDLookAhead = 'off';
options.Constraints = 'on';
options.OpenLoop = 'off';
% Rode a simulação
MPCopt = mpcmoveopt;
% Defina o tempo de simulação [m]
tsim = 360;
dt = 1;
t = 0:dt:tsim;
N = length(t);
x = mpcstate(mpcCh);
s = zeros(N,19);
u = zeros(N,4);
y = zeros(N,3);
r = [557 5.1 3.14]';
v = 160;
for i = 1:N
    s = x.Plant;
    y(i, :) = mpcCh.Model.Plant.C*s;
    [u(i, :), info] = mpcmove(mpcCh, x, y(i, :), r, v, MPCopt);
end
fprintf('%10.2f\n', info.Xopt(1, :))
```

A.VI - OTIMIZAÇÃO MOGA

```
% Limpe as variáveis e as plotagens
% clear variables
clear variables
close all
clc
global mpcCh
global r
global v
global tsim
global options
CreateModel();
h = 2;
p = 50;
SetHorizons(h, p)
% Configure as restrições
SetRestrictions()
% Valores iniciais
DefineInitialStates()
% Escalas e ganhos iniciais
p = ones(10, 1);
SetWeights(p)
% Defina o tempo de simulação [m]
dt = 1;
tsim = 360;
ts = 0:dt:tsim - dt;
% Gere as referências
r = CreateReferences(tsim, dt);
% Defina os sinais das perturbações medidas
v = ones(tsim, 1)*160;
% Especifique as opções de simulação
options = mpcsimopt();
options.RefLookAhead = 'off';
options.MDLookAhead = 'off';
options.Constraints = 'on';
options.OpenLoop = 'off';
mpcverbosity off;
rng default
ga_options = optimoptions('gamultiobj', 'PlotFcn', @gaplotpareto);
nvars = 10;
lb = 1e-1*(ones(nvars, 1));
ub = 100*(ones(nvars, 1));
x = gamultiobj(@SimOptimizedMPC, nvars, ...
    [], [], [], [], lb, ub, ga_options);
Return
```

A.VII - PLOTAGEM DOS RESULTADOS

```

close all

load r r
load T T
load ys ys
load ym ym
load us us
load um um

% Plote os resultados para comparação
t = 0:T - 1;

figure
plot(t, r(:, 1), 'b--', t, ys(:, 1), 'm', t, ym(:, 1), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('TIC-23099 [C]')
title('Simulação da TIC-23099')
legend('Referência', 'Modelo sem H', 'Modelo com H')
grid

figure
plot(t, r(:, 2), 'b--', t, ys(:, 2), 'm', t, ym(:, 2), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('AIC-23001 [% O2]')
title('Simulação da AIC-23001')
legend('Referência', 'Modelo sem H', 'Modelo com H')
grid

figure
plot(t, r(:, 3), 'b--', t, ys(:, 3), 'm', t, ym(:, 3), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('PIC-23039 [bar]')
title('Simulação da PIC-23039')
legend('Referência', 'Modelo sem H', 'Modelo com H')
grid

figure
subplot(221)
plot(t, us(:, 1), 'b--', t, um(:, 1), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('FIC-23027.SP [m3/h]')

```

```
title('Simulação da FIC-23027.SP')
legend('Modelo sem H', 'Modelo com H')
grid
```

```
subplot(3, 1, 1)
plot(t, us(:, 1), 'b--', t, um(:, 1), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('FIC-23027.SP [m3/h]')
title('Simulação da FIC-23027.SP')
legend('Modelo sem H', 'Modelo com H')
grid
```

```
subplot(3, 1, 2)
plot(t, us(:, 2), 'b--', t, um(:, 2), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('FIC-23028.SP [m3/h]')
title('Simulação da FIC-23028.SP')
grid
```

```
subplot(3, 1, 3)
plot(t, us(:, 3), 'b--', t, um(:, 3), 'k')
ax = gca;
ax.XAxis.Exponent = 0;
xlabel('t [m]')
ylabel('FIC-23025.SP [m3/h]')
title('Simulação da FIC-23025.SP')
grid
```

A.VIII - SIMULAÇÃO DA PLANTA

```
% Preparação do ambiente
clc
clear variables
close all
mpcverbosity off;

% Leia os dados coletados para o forno
[plant, nominal] = DefinePlant;

% Identifique o modelo do forno
model = IdentifyPlant(plant);

Ts = 1;
ctrl = CreateMPC(model, Ts, nominal);

% Preparação para a simulação
T = 360;
opt = mpcsimopt(ctrl);

% Criação de distúrbios constantes proporcionais às faixas das variáveis de saída
T_start = 30;
T_to_finish = T - T_start;

disturbance = [repmat([0 0 0], T_start, 1); repmat([0 0 -2], T_to_finish, 1)];
% disturbance = [zeros(T_start, 3); [4 1 0.5].*randn(T_to_finish, 3)];

opt.UnmeasuredDisturbance = disturbance;
opt.Model = ctrl.Model.Plant;

% Valor estático da perturbação medida
v = 144.4543;

% Criação da referência (média das controladas)
r = GenerateReferences(nominal.y, T, false);

% Simulação do controlador e da planta externa com o
% modelo de perturbação de ganho unitário
rng default
ctrl.Model.Disturbance = ss(eye(3), eye(3), eye(3), 0*eye(3), 1, 'TimeUnit', 'minutes');
% ctrl.Model.Disturbance = ss(eye(3));
[ys, ts, us] = sim(ctrl, T, r, v, opt);

% Simulação do controlador e planta externa com o modelo de perturbação
% não medida de entrada gerado na identificação
UD_model = ss(model.A, model.B(:, 5:7), model.C, model.D(:, 5:7), Ts);
UD_model.TimeUnit = 'minutes';
ctrl.Model.Disturbance = UD_model;
[ym, tm, um] = sim(ctrl, T, r, v, opt);
```

```
% Apresente os IAEs
IAEs = sum(abs(r - ys));
IAEm = sum(abs(r - ym));
fprintf('IAEs do MPC sem H: %8.4f %8.4f %8.4f\n', IAEs)
fprintf('IAEs do MPC com H: %8.4f %8.4f %8.4f\n', IAEm)
```

```
save r r
save T T
save ys ys
save ym ym
save us us
save um um
```

```
PlotMPCResults
```

```
G = model;
H = UD_model;
```

A.IX - MODELO DA PLANTA AUMENTADO

O modelo abaixo apresenta a planta identificada na estrutura ARMAX convertido para o espaço de estados na forma aumentada é apresentada aqui.

A =

	x1	x2	x3	x4	x5	x6	x7	x8	x9
x1	1.653	-1.258	0.6983	1	0	0	0	0	0
x2	0.00355	1.618	-0.2388	0	1	0	0	0	0
x3	-0.01358	-0.04519	0.6756	0	0	1	0	0	0
x4	-0.6713	1.139	-0.6632	0	0	0	1	0	0
x5	-0.003357	-0.6504	0.2325	0	0	0	0	1	0
x6	0.01191	-0.008585	0.3079	0	0	0	0	0	1
x7	0	0	0	0	0	0	0	0	0
x8	0	0	0	0	0	0	0	0	0
x9	0	0	0	0	0	0	0	0	0

B =

	FIC-23027.SP	FIC-23028.SP	FIC-23025.SP	FIC-23003	UD1	UD2	UD3
x1	0.001862	0.002504	-0.000127	-0.02275	0.1475	-0.05085	0.01998
x2	-0.001257	-0.00101	3.282e-05	0.002635	0.0003779	0.04631	-0.006834
x3	-4.779e-05	-3.052e-05	2.195e-05	-0.002961	-0.001445	-0.001826	0.03946
x4	-0.0008697	-0.001235	0.0001528	-0.006189	-0.06904	0.04604	-0.01898
x5	0.001066	0.0008149	-2.104e-05	-0.001397	-0.0003574	-0.03061	0.006652
x6	6.969e-05	-4.589e-05	-1.125e-06	-0.002683	0.001268	-0.0003469	0.02123
x7	0	0	0	0	0.01103	0	0
x8	0	0	0	0	0	-0.003422	0
x9	0	0	0	0	0	0	0.007783

C =

	x1	x2	x3	x4	x5	x6	x7	x8	x9
TIC-23099	1	0	0	0	0	0	0	0	0
AIC-23001	0	1	0	0	0	0	0	0	0
PIC-23039	0	0	1	0	0	0	0	0	0

D =

	FIC-23027.SP	FIC-23028.SP	FIC-23025.SP	FIC-23003	UD1	UD2	UD3
TIC-23099	0	0	0	0	0.1065	0	0
AIC-23001	0	0	0	0	0	0.04041	0
PIC-23039	0	0	0	0	0	0	0.02861

Input delays (sampling periods): 1 1 1 1 0 0 0

Input groups:

Name	Channels
Manipulated	1,2,3
Measured	4
Unmeasured	5,6,7

Output groups:

Name	Channels
------	----------

Measured 1,2,3

Sample time: 1 minutes

Discrete-time state-space model.

APÊNDICE B

B.I - CONTROLADORES PREDITIVOS MULTIVARIÁVEIS COMERCIAIS

O objetivo desta secção é apresentar os principais controladores preditivos multivariáveis, disponíveis comercialmente. Nesta secção discorrerá de maneira resumida as principais características dos controladores preditivos multivariáveis disponíveis no mercado.

B.II - CONTROLADOR PREDITIVO MULTIVARIÁVEL- PACE YOKOGAWA

O fabricante Yokogawa tem em seu portfólio de produtos, na divisão de controle e automação, uma plataforma de controle preditivo multivariável de processos e estimadores de estados (sensores virtuais) denominada, PACE (*Platform for Advanced Control and Estimation*). O controle avançado de processos PACE, incorpora em sua estrutura: os controles multivariáveis, estimativa de qualidade, cálculos customizados, complexos e design de interface do usuário. Estas funcionalidades estão reunidas em uma única aplicação ou ferramenta computacional.

A plataforma PACE, assim como o controlador DMC, não incorpora a matriz de perturbações não medidas, isto é, as perturbações não medidas não estão contidas diretamente no modelo da planta. A estrutura do PACE, admite a inclusão somente dos distúrbios medidos - DV (*Disturbances Measured*), variáveis manipuladas - MV (*Manipulated Variables*) e variáveis controladas - CV (*Controlled Variables*).

Todavia, a soluções de controle avançado da Yokogawa, disponibiliza dois mecanismos de resolução de problemas de variações randômicas, oriundas de erros no modelo de predição, ruídos provenientes de sensores de processo (PINTO, 2016).

Um dos mecanismos utilizados pelo controle Avançado PACE, para variações randômicas, é o filtro de Kalman (KALMAN; ENGIAR; BUEY, 1962). Esta solução disponibiliza atualizações on-line do modelo do processo, incorporado a todas as variáveis POV (*Process Output Variables*), que são variáveis passíveis de predição através do comportamento futuro, por meio dos modelos identificados.

A este conjunto de variáveis medidas estão compreendidas as variáveis controladas (CV), funções econômicas, sendo que estas podem ser otimizadas, e variáveis intermediárias. As variáveis intermediárias, são apenas utilizadas como ponto de monitoramento notável do comportamento da

planta e não de controle, isto é, uma variável intermediária detecta distúrbios não medidos, refletindo no cálculo da predição futura, corroborando para a antecipação de ações corretivas. Estas variáveis não medidas estão relacionadas com perturbações oriundas de ruído de sensores ou medidores de grandezas primárias.

O estimador de Kalman é um algoritmo que utiliza um conjunto de medições e os ruídos (variações aleatórias) associados a esta variável, em uma determinada taxa de amostragem, buscando estimar o comportamento de um sistema ao longo do tempo, ou seja, o filtro de Kalman se baseia em modelos estocásticos. Esta solução pode ser aplicada em sistemas de controle observáveis, sujeitos a ruídos ou onde os parâmetros não podem ser medidos. Na Figura 107 é mostrado o diagrama esquemático do filtro de Kalman para distúrbios não medidos.

Figura 107 – Diagrama de blocos do Filtro de Kalman para perturbações não medidas, controle avançado PACE.

Fonte: Adaptado ((PINTO, 2016).

O controlador PACE, admite a incorporação das funções de transferência paramétricas aos modelos de: -1ª. Ordem, -1ª. Ordem Beta, -Rampa 1ª, Ordem-Ganho Zero, Ganho Zero 1ª. Ordem, Ganho Zero 2ª, Ordem Beta, 2ª. Ordem, 2ª. Ordem sobre/sub amortecido, 2ª. Ordem Inversa Beta, 2ª. Ordem Overshot Beta. O controle avançado da estrutura PACE, é um componente nativo do Sistema Digital de Controle da Yokogawa (DCS - Digital Control System). É parte inerente da arquitetura do DCS da Yokogawa, uma interface de engenharia com as ferramentas para: parametrização das aplicações, identificação de sistemas, desenvolvimento do controle avançado (APC-Advanced Control Process), correlação e análise de dados, validação de modelos e recursos relacionados a gráficos e dados de tendências.

Esta interface é chamada de AINDA (*Advanced Identification and Data Analysis*), está conectada diretamente no barramento das estações controle (AMRIT *et al.*, 2015). Nas Figura 108 e 109 é disponibilizada a arquitetura do DCS da Yokogawa com a interface APC e ferramentas de identificação e validação.

Figura 108 – Arquitetura do Sistema Digital de Controle Yokogawa com Interface APC.

Fonte: Yokogawa Electric Corporation (2015).

Figura 109 - - Advanced Identification, Data Analysis and Controller Design.

Fonte: Yokogawa Electric Corporation (2015).

O sistema PACE permite múltiplas funções econômicas que podem ser otimizadas simultaneamente. O projetista pode priorizar funções econômicas entre si, versus restrições. Essas funções econômicas são otimizadas na ordem decrescente de prioridades até que todos os graus de liberdade estejam esgotados. É possível o desenvolvedor do controle avançado estipular a prioridade das funções econômicas, contrapondo uma com as outros. O controle multivariável permite a estabilização ótima do processo, tendo como resultado o aumento da produtividade, isto é, a solução PACE, fornece uma solução de controle preditivo utilizando uma correlação cruzada do processo, que em muitos casos, diminui significativamente a variabilidade da planta, e garantindo a manutenção da qualidade dos produtos (AMRIT *et al.*, 2015).

B.III - SISTEMA DE CONTROLE - SICON

O Sistema de Controle (SICON), desenvolvido pela equipe técnica da PETROBRAS, reúne em um único ambiente computacional, as ferramentas necessárias para o desenvolvimento de aplicações para o controle avançado de processos multivariável. Este ambiente computacional, permite o desenvolvimento das atividades para a construção e implementação de soluções, para o controle de processos.

Além de fornecer um ambiente integrado, o SICON propicia a configuração do controlador preditivo, comissionamento e análise de desempenho da aplicação ou solução de controle. A implementação é realizada através de linguagem inteligível (Visual Basic), facilitando o desenvolvimento do controlador (MORO; CAMOLESI; ZANIN, 2008).

O SICON é uma arquitetura cliente-servidor, facilitando o sincronismo dos sinais de controle, gerenciamento de recursos e serviços de forma centralizada, permitindo escalabilidade. O pacote de software é homologado e possui finalidades específicas, seguindo os padrões internacionais. O sistema consiste em duas plataformas: hardware (computador de controle de processos), software (ferramentas computacionais de engenharia).

Uma das características importantes da arquitetura do SICON é a integração com o sistema PI (*Plant Information*) e o Sistema Digital de Controle Distribuído (SDCD), ou seja, o sistema se comunica através de uma interface OPC (OLE for Process Control) com a camada de controle e PI, tornando flexível a implementação de inferências e otimização de variáveis de controle (CAMOLESI; MORO; ZANIN, 2008).

A plataforma do SICON, disponibiliza um editor para o desenvolvimento do controlador e inferências (analisadores virtuais). O módulo de desenvolvimento da aplicação (controlador e inferências) é considerado o elemento principal do sistema.

Os algoritmos disponíveis para a implementação do controle avançado no SICON são: LDMC (Linear Dynamic Matrix Control) e DMC (*Dynamic Matrix Control*). Todavia, esta arquitetura não permitem a inclusão do modelo de perturbações não medidas.

No ambiente de desenvolvimento do controle avançado do SICON, estão disponíveis uma coleção ou biblioteca de métodos consolidado para controle e inferência. Este tipo de topologia, torna possível o reaproveitamento de soluções de projetos consolidadas.

Através da interface de implementação do controle avançado, o projetista tem acesso as principais funcionalidades, do sistema. Neste ambiente computacional, estão disponíveis as principais funcionalidades, relacionadas com a manipulação dos seguintes objetos de dados e conexão, que são:

1. Variáveis controladas;
2. Variáveis manipuladas;
3. Perturbações medidas;
4. Conexão das TAGs do PI, que serão a fonte de dados de entrada e saída;
5. *Point source* do SDCC, leitura de dados diretamente da interface do SDCC;
6. Sintonia e ajustes dos parâmetros de inferência do Controlador preditivo;
7. Avaliação do comportamento dinâmico do sistema, (gráficos de tendência);
8. Chaveamento da aplicação em modo malha aberta ou fechada.

O Sicon realiza a conexão de cliente servidor, através das interfaces com as bases de dados. Estas bases de dados mantem residentes arquivos do tipo tabela, oriundos das fontes de dados do SDCC e PI. Como a aplicação (SICON) está em rede, isto é, topologia cliente-servidor, softwares comerciais podem ser utilizados para por exemplo: identificação do modelo da planta e incorporação a estrutura do SICON.

Esta característica da arquitetura do sistema garante uma interação entre a aplicação e outras ferramentas comerciais, uma vez que os elementos de conexão de rede atendem ao padrão ODBC (*Open Data Base Connectivity*) (MORO; CAMOLESI; ZANIN, 2008).

A estrutura de banco de dados utilizada no sistema, permite recuperar os arquivos em formato compatível com as ferramentas comerciais, de identificação de modelos da dinâmica do processo. O padrão ODBC disponibiliza estas funcionalidades de conectividade e recuperação de dados de uma forma similar a ferramenta PI-Data-Link (suplemento Excel™ – OLE).

Na versão inicial do SICON, utiliza-se o software SMC-MODEL, como ferramenta para identificação do modelo do processo. Na versão atual, o SICON dispõe de uma ferramenta de identificação chamado BR-VIP. Esta ferramenta computacional de identificação foi desenvolvida através de um projeto P&D entre PETROBRAS e pesquisadores da Universidade de São Paulo. O

BR-VIP, que dispõe de funcionalidades que permitem a identificação de modelos de processos, correlação entre variáveis, validação de modelos, entre outras.

Na Figura 110 é mostrada a topologia cliente servidor para as aplicações do controle avançado SICON, com os respectivos componentes da topologia cliente servidor (Banco de dados, Interfaces, *archive*, etc), de acordo com as descrições nos parágrafos anteriores.

Figura 110 – Topologia cliente –servidor para aplicações do controle avançado SICON.

Fonte: Adaptado (MORO, 1997).

O sistema realiza a transferência de dados entre as aplicações, de acordo com a Figura 23. O mecanismo utilizado para a comunicação e troca de dados entre as aplicações é *socket*. O socket é normalmente utilizado na topologia cliente/servidor, e possibilita a troca de mensagens entre os processos de uma máquina e uma aplicação servidor, e de uma máquina e uma aplicação cliente. As funções principais do servidor do SICON é prover os seguintes serviços:

1. Ler dados da base de dados do PI™;
2. Ler dados da base de dados do SICON;
3. Escrita de dados na base de dados do SICON;
4. Escrita de dados na base de dados do SDCD;
5. Transferência de dados entre as aplicações;

6. Recebimento e buferização de dados enviado pelas aplicações;
7. Comunicação e manipulação de Arquivo de modelos DMC;
8. Comunicação e troca de dados com a interface do SDCCD;
9. Gerenciamento das aplicações de controle multivariável e inferências.

Toda a troca de dados realizada entre o servidor e aplicações é estabelecida através de rotinas implementadas através do sistema operacional Windows, a razão pela seleção deste sistema é em virtude do domínio da tecnologia está disseminada na comunidade científica.

O controle avançado é executado pelo programa MVCctrl, trata-se de um algoritmo de controle dos dados fornecidos pelo servidor do SICON. Na inicialização do programa MVCctrl, a aplicação requisita ao servidor as configurações e parametrizações que serão utilizadas. Estas configurações são: o número de variáveis controladas e manipuladas, perturbações medidas e variáveis auxiliares, modelo de resposta ao degrau.

Concluída esta etapa (algoritmo), o controlador realiza a alocação de espaço em memória necessária para execução da aplicação. Posterior a conclusão da execução do algoritmo, a aplicação transmite os resultados (resolução do problema de controle) para o servidor. Na sequência, o servidor do SICON, envia os resultados obtidas da aplicação MVCctrl para a interface do SDCCD, para que seja implementada as ações na camada de controle. A estrutura disponível referente ao modelo da dinâmica do processo é LMDC e DMC.

O algoritmo executa a otimização em estado estacionário, através de uma programação linear, situada em uma camada superior do controlador. Na Figura 111 é disponibilizado o diagrama com o fluxo da troca de dados entre as aplicações do sistema Sicon.

Figura 111 – Arquitetura do Sistema de controle SICON e fluxo de dados entre as aplicações.

Fonte: Adaptado (MORO,1997).

Por fim, o servidor do SICON conta com serviço auxiliar de execução de backup da base de dados. Esta aplicação é responsável por manter os arquivos do projeto do usuário atualizados, permitindo recuperar os dados (*download e upload*) por meio de um controle de versão, indexada. O SICON é considerado uma ferramenta versátil e de baixo custo, que propicia o desenvolvimento de soluções de controle avançado aderentes a necessidade do usuário (MORO, 1997).

B.IV - CONTROLADOR DELTA V PREDICT™

O controlador preditivo da Emerson Process é uma solução comercial, para processos complexos, multivariáveis e com tempo morto elevado.

A ferramenta DeltaV Predict™, disponibiliza uma biblioteca de componentes e blocos de função de engenharia, que permite desenvolver as estratégias de controle multivariáveis, validar a solução e testar o controlador preditivo antes da aplicação no processo. Todas as funcionalidades do DeltaV Predict™ estão incorporadas na plataforma do sistema digital de controle distribuído (SDCD) DeltaV. O DeltaV é um sistema de controle que, realiza a supervisão e controle de processos ou plantas industriais. Na Tabela 31 são relacionadas as ferramentas computacionais disponíveis no SD CD DeltaV.

A ferramenta Delta V Predict™ permite uma abordagem interativa, para a implementação do modelo de controle preditivo multivariável, através do bloco de função MPC.

Tabela 31– Ferramentas computacionais do SDCD DeltaV -Emerson Process

Aplicação	Descrição
DeltaV Tune	Sintonia de Malha de Controle
DeltaV Fuzzy	Lógica Nebulosa e Controle Adaptativo
DeltaV Predict	Controle Preditivo Multivariável
DeltaV Model Identification	Módulo de Identificação de Sistemas
Control Optimization	Otimização de processos
DeltaV Neural	Sensores virtuais e Inferência
DeltaV Adaptive	Controle adaptativo bloco de função PID

Fonte: Autor.

Conforme destacado inicialmente, o Delta V Predict™ pode ser aplicado em processos com múltiplas entradas passíveis de serem manipuladas e controladas, processos com perturbações medidas e/ou restrições dinâmicas complexas associadas, tais como tempo morto e resposta inversa. A taxa de execução do bloco do controlador preditivo pode ser configurada através da interface DeltaV Predict™, desta maneira é possível ajustar a velocidade de processamento do algoritmo às exigências das características do processo.

O DeltaV Predict™ conta com filtros lineares e não lineares, para ruído oriundo de sensores, não sendo necessário implementar lógica externa. As técnicas de filtragem não lineares podem ser utilizadas através de parametrização, quando ruídos de instrumentação ou perturbações medidas estão presentes no processo.

A aplicação DeltaV Predict™ possibilita conexão com outras aplicações externas ao SDCD, a troca de dados pode ser implementada através do protocolo OPC.

As configurações da estratégia de controle e modelos identificados, são armazenadas em um banco de dados, incorporado na arquitetura do SDCD DeltaV. O sistema Delta V Predict™ usa a estrutura matemática ARX (Auto Regressivo com Entradas Externas), os parâmetros desta estrutura são identificados através da resposta de impulso finito (FIR).

Através do bloco do controlador preditivo, é possível ajustar os parâmetros relacionados com horizonte de controle, penalidade de movimento (PM), penalidade por erro (PE). Os valores ajustados na penalidade de movimento, altera a margem de estabilidade do controlador, ou seja, valores superiores de PM aumentam a margem de estabilidade. Os ajustes do parâmetro PE afetam as variáveis de saída, correlacionado o grau de relevância de cada controlada (SARGAR; SONDKAR; PROPERTIES, 2013).

O fabricante Emerson Process dispõe de ferramentas adicionais para identificação, otimização linear de processo (LP) e simulação do controlador preditivo, este pacote de soluções é chamado de

DeltaV PredictPro™. Estas ferramentas são nativas do SDCD DeltaV, porém é necessário que o usuário adquira a licença, para utilização dos pacotes de softwares.

Através da interface de desenvolvimento, o projetista pode testar a aplicação e simular as estratégias de controle preditivo. O DeltaV Predictiv™, permite acelerar a execução das estratégias de controle 100 vezes mais rápidas que o tempo real.

O historiador contínuo do DeltaV coleta automaticamente dados das entradas e saídas usadas no bloco de função MPC. Todos os dados adquiridos durante o teste de performance do controlador MPC, podem ser visualizados através da interface do historiador. O controlador preditivo pode ser gerado automaticamente, com a utilização do bloco MPC, disponível na biblioteca do sistema. A partir dos testes de identificação do modelo do processo, através da ferramenta PredictPro™, o controlador é gerado automaticamente.

A Figura 112 mostra os blocos do controlador preditivo MPC, isto é, é um objeto da biblioteca de funções do DeltaV, quando adquirido com a licença DeltaV Predict™. O bloco MPC fornece as entradas para as variáveis controlas e manipuladas, sintonia do controlador, *tracking* da saída, quando os sinais de medição estão abaixo ou acima dos valores operacionais, isto é, falha dos sinais de medição (BLEVINS, 2015).

Figura 112 – Bloco do Controlador Preditivo MPC – Biblioteca DeltaV –SDCD.

Fonte: Adaptado (EMERSON PROCESS MANAGEMENT, 2009).

As entradas de perturbação do processo (*DV-Disturbances Variables*) são perturbações medidas. O controlador usa os últimos valores da medição, até novos valores estarem disponíveis. O algoritmo do MPC prevê o gerenciamento dos status de medições, ou seja, as variáveis consideradas dentro da faixa operacional são lidas, caso contrário o controlador entra em modo manual.

O modelo do processo (matriz dinâmica) é gerado *off-line* e incorporada ao controlador no sistema DeltaV™, posterior à validação. Com relação ao horizonte de predição o valor máximo é 120 *step*, e o horizonte de controle é 16 *step*.

Figura 113 – Diagrama de Blocos do Controlador MPC da Emerson Process.

Fonte: (BLEVINS, 2015).

B.V - HONEYWELL ROBUST MPC TECHNOLOGY

Historicamente, a terceira patente referente ao desenvolvimento de controle preditivo multivariável foi o RMPCT (*Robust Multivariable Predictive Control Technology*) da Honeywell. Esta tecnologia identificava o modelo através da resposta ao impulso finito, para em seguida utilizar o modelo identificado no domínio de Laplace.

Atualmente, o fabricante Honeywell oferece soluções para controle avançado e otimização de processos, através da ferramenta *Advanced Control Solutions*. O pacote de software para controle avançado e otimização de processos é modular, permitindo ao usuário, adicionar novas funcionalidades ou ferramentas computacionais, de acordo com a necessidade. Trata de uma plataforma integrada e unificada, dos produtos para controle avançado de processos, com flexibilidade para conexão com outras ferramentas computacionais externas ao ambiente Honeywell. As soluções disponibilizadas pelo fabricante são: *Control Performance Monitor (CPM)*, *Profit® Control and Optimization from Honeywell* e *Comprehensive Closed-Loop Tuning Solution*. A ferramenta computacional CPM reúne funcionalidades para monitoramento e avaliação do desempenho do controle avançado de processos, identificação e validação do modelo matemático do processo. Além das funcionalidades relacionadas com o controle avançado, a ferramenta disponibiliza

o monitoramento de desempenho de controle regulatório PID e ativos associados ao controle, identificando e diagnóstico de problemas relacionados com a variabilidade do processo ocasionados pelo baixo desempenho dos sistemas de controle.

O pacote de soluções para controle avançado da Honeywell disponibiliza relatórios automatizados relacionados ao benchmarking de desempenho individuais dos sistemas de controle regulatório, isto é, através desta ferramenta é possível acompanhar e gerenciar o desempenho dos ativos da planta (instrumentação e controle) (CASTELIJNS, 2013).

O ambiente de engenharia, para desenvolvimento do controlador preditivo multivariável da Honeywell, disponibiliza estrutura para geração de modelos de dinâmicas de processos lineares, não lineares, em subespaços dinâmicos (espaço de estados). Todavia, as estruturas de modelos disponíveis no ambiente de desenvolvimento são ARX e ARMAX. O desenvolvimento do modelo da dinâmica do processo é realizado off-line, através da utilização de banco de dados relacional, em tempo real. O sistema Honeywell propicia a conexão com outras interfaces de fontes de dados (Banco de Dados) e sistemas de controle DCS, isto é, o MPC da Honeywell pode conectar-se com os Historiadores PI® (Plant Information), Aspen IP21®, Interface LMS Amesim Siemens®, Matlab®, entre outros (vide Figura 116).

Figura 114 – Conectividade do Controle Preditivo Honeywell com interfaces comerciais.

Fonte: (VON WISSEL *et al.*, 2016).

O ambiente de desenvolvimento do controle avançado, reúne todas as funcionalidades para: importação manipulação dados, identificação, simulação, validação de modelos, re-identificação, comunicação com outras fontes de dados através da interface Matrikon OPC, suporte a virtualização de medições analíticas (analisadores virtuais).

A solução Honeywell para controle preditivo MPC, conta com as opções emulação e teste de performance do controlador (CASTELIJNS, 2013). No ambiente de engenharia de desenvolvimento do controle avançado é disponibilizada a opção de sintonia do controlador, através de método de otimização de parâmetros. Na Figura 115 é mostrada a interface de desenvolvimento e modelagem do controle preditivo da Honeywell, chamado de RMPCT *modelling interface – Profit Design Studio*.

Figura 115 – Interface de modelagem do controle preditivo Honeywell – Profit Design Studio.

Fonte: (CAMPHER, 2011).

A solução Honeywell permite a simulação do controle avançado de acordo com o cenário configurado, para treinamento de operadores de processos. Toda as aplicações são estanciadas em uma arquitetura cliente-servidor, ou seja, as ferramentas de desenvolvimento e comunicação funcional em rede, mantendo arquivos com confiabilidade e disponibilidade on-line. Uma das interfaces padrão utilizada pelo sistema e MatrikonOPC®.

A ferramenta Honeywell *Profit Design Studio*, conduz o projetista para um fluxo de desenvolvimento implementação do controle preditivo, com base em um ciclo vida do projeto e operação do APC (*Advanced Process Control*).

O ciclo de vida compreende o desenvolvimento, implementação, operação, manutenção e reparo. Na Tabela 32 é mostrado o fluxo de implementação do controle preditivo Honeywell e suporte para aplicação durante o ciclo de vida da solução.

Tabela 32 – Fluxo do Ciclo de vida da Solução do Controle Preditivo Honeywell.

Aplicação	Descrição
<i>Design</i>	Avalia os objetivos do controle do processo, identificação das variáveis controladas e manipuladas;
<i>Implement</i>	Identifica modelo, testa e valida a solução e implementa controlador;
<i>Operate</i>	Treinamento de operadores através de Simulação;
<i>Maintain</i>	Manutenção, garantir a geração contínua de benefícios do controle avançado durante o ciclo de produção.
<i>Repair</i>	Monitoração e reparo da aplicação APC, quando os objetivos operacionais não são cumpridos.

Fonte:(CASTELIJNS, 2013).

O algoritmo do APC da Honeywell, incorpora controle dinâmico baseado em modelos lineares, lineares e misto, isto é, pode admitir em um único controlados ambos modelos (VON WISSEL *et al.*, 2016). A estrutura interna do controlador preditivo, APC-Honeywell (Advanced Process Control) é formada por um estimador de estados, otimizador de trajetória, linearizador em espaço de estados, estruturas dos modelos não lineares e lineares, de acordo com a dinâmica do processo. Outra funcionalidade contida na estrutura controlador Honeywell, é a possibilidade de mudança ou chaveamento de classe ou faixa de controle da planta em regime on-line, ou seja, o controlador calcula as trajetórias das variáveis manipuladas e controladas, para atender os novos critérios de controlabilidade (faixa de operação).

Na Figura 116 é mostrado através do diagrama de blocos a estrutura interna do controlador preditivo, APC Honeywell.

Figura 116 – Diagrama de blocos da estrutura interna do APC Honeywell.

Fonte: (CASTELIJNS, 2013).

O controle preditivo Honeywell, disponibiliza entradas para perturbações medidas e filtros para perturbações não medidas. As perturbações não-medidas são consideradas como sinais de ruído branco provenientes de sensores (instrumentos de medição).

B.VI - MULTIVARIABLE CONTROL FOR INDUSTRIES 3dMPC® - ABB

O 3dMPC é um pacote de software para a implementação do controlador preditivo multivariável e otimização de processos. A sintonia do controlador é realizada através de uma interface conectada ao sistema através da arquitetura cliente servidor.

A etapa de configuração do controlador preditivo consiste em estabelecer quais variáveis controlada, manipuladas, perturbações medidas, serão utilizadas. Estes sinais são aquisitados do DCS (*Digital Control Systems*) ou SDCCD – ABB.

Uma vez definida as variáveis que farão parte sistema de controle MPC, a segunda etapa é a coleta de dados para identificação do modelo da dinâmica do processo. Estas funcionalidades são integradas ao sistema, e fornece ao usuário uma alternativa para realizar os experimentos de identificação do processo, e armazenamento dos dados em uma arquitetura cliente-servidor.

O controlador inclui ferramentas de modelagem que, propiciam a realização dos testes de identificação avançada, para construção de modelos em espaço de estado. A ferramenta computacional 3dMPC, disponibiliza gráficos e funções de análise de aderência do modelo identificado. A solução ABB para controle avançado, inclui funcionalidade para a sintonia ou ajustes do controlador preditivo 3dMPC, ambiente de simulação interativo com o operador do sistema, permitindo análise dos resultados através de interface gráfica.

O 3dMPC fornece três graus de liberdade para o controle de otimização dinâmica. O controlador pode ser configurado para realizar automaticamente, respostas dinâmicas diferentes para mudanças relacionadas aos seguintes eventos: mudança de *set-point*, perturbações mensuráveis, compensação de distúrbios medidos (ABB, 2016). O pacote de software do 3dMPC inclui os componentes de configuração do controlador, troca de dados do controlador on-line via OPC, estrutura para modelos lineares e não lineares.

Além das funcionalidades destacadas o controlador pode funcionar como um ambiente de treinamento e simulação para operadores. A Figura 117 mostra uma visão geral dos componentes do 3dMPC e como seus diferentes módulos se inter-relacionam.

Figura 117 – Diagrama de blocos dos componentes do controle preditivo 3dMPC.

Fonte: (JOHANSSON, 2002).

A estrutura do 3dMPC prevê entradas para perturbações medidas, não está previsto modelo de perturbações não medida. O controlador 3dMPC usa a combinação de *feedforward* com métodos de predição. O controlador determina as variáveis manipuladas (MV) com base nas medições reais das variáveis controladas e variáveis de perturbação (DV). As variáveis de processo são controladas pela lei de controle e pelo observador de estados, para melhoria e estimativa do estado do processo. Os sinais de perturbações devem ser mensuráveis.

O algoritmo do controlador calcula através do horizonte predição o comportamento futuro da planta ou processo, isto é, a cada intervalo de amostragem as variáveis manipuladas são calculadas e combinadas a partir de uma sequência de otimizações, de acordo com a função objetivo.

A função de perda neste problema de controle, penaliza, através da uma soma ponderada do quadrado dos erros, para posterior atualização das manipuladas. As especificações das restrições, que participam do método de otimização, provem requisitos (faixas) para as saídas das variáveis manipuladas de controladas.

O nome 3dMPC®, significa três graus de liberdade, que significa que o controlador pode ser configurado para diferentes respostas dinâmicas, tais como: mudança de *set-point*, alterações nos distúrbios ou perturbações medidas, outros distúrbios incompatíveis com o modelo. Os três diferentes problemas de otimização são resolvidos através de uma formulação individual, disponibilizada pelo algoritmo do controlador.

No algoritmo do controlador 3dMPC, é previsto que os sinais de entradas e saídas, podem operar em modos operacionais distintos, isto é, significa que alguns sinais do controlador podem trabalhar no modo automático, enquanto outros podem operar em modo manual. O modo de operação de um sinal é determinado pelo operador ou por entradas externas para os três módulos do controlador MPC (graus de liberdade).

Uma das características do 3dMPC é a capacidade de lidar com as restrições das variáveis manipuladas e controladas. As restrições são classificadas com a prioridade individuais para variáveis controladas, desvios e variáveis manipuladas.

Estas restrições podem ser violadas em condições de operacionais excepcionais, de acordo com as prioridades. As limitações *hard*, podem ser definidas para saídas manipuladas de acordo com a taxa de variação dos elementos finais de controle.

O controlador 3dMPC é baseado em um modelo de espaço de estado de tempo discreto, o vetor de estado ativo é estimado e atualizado como uma tecnologia de observadores de estados.

O modelo em espaço de estado fornece um tratamento uniforme das dinâmicas para processos estáveis, integradores e instáveis, permite tratamento de distúrbios não mensuráveis, utilizando medições adicionais e fornece ao controlador a capacidade para lidar com processos não lineares (ÅKESSON, 2002).

Na Figura 118 – Diagrama de blocos do Controlador 3dMPC – ABB.

Figura 118 – Diagrama de blocos do Controlador 3dMPC – ABB.

Fonte: (ABB, 2016).

As soluções para controle multivariável da ABB, engloba desde o processo de identificação do modelo da dinâmica do processo, desenvolvimento, implementação e acompanhamento de

performance do controlador. Todas estas funcionalidades são modulares, permitindo ao projetista maior flexibilidade para o projeto de sistemas de controle multivariável. Contudo neste ambiente de desenvolvimento não é evidenciado opções de inserção de estrutura de modelo com perturbações não medidas, isto é, perturbações características de ruído colorido.

B.VII - PAVILION8® MODEL PREDICTIVE CONTROL

O algoritmo de controle preditivo Pavilion8® soluciona problema de minimização da função objetivo, utilizando o modelo da dinâmica do processo em sua estrutura, de maneira a prever a resposta das ações de controle nas variáveis controladas em um dado número de horizontes de predição, dentro da função custo.

A função custo do MPC Pavilion8®, tem como proposito, minimizar o erro entre as trajetórias de referência e a variável controlada, e os degraus nas ações de controle. A ferramenta computacional para controle e otimização Pavilion8, disponibiliza diversas funcionalidades para configuração do controlador.

As principais funções disponibilizadas pelo ambiente de desenvolvimento são: função custo CV-Desired, função MV Limits, utilizada para definir limites de mínimo e máximo para as variáveis manipuladas, e a função MV Rate of Change, utilizada para definir a taxa de incrementos ou decrementos dos movimentos das variáveis manipuladas.

O sistema Pavilion8, disponibiliza uma interface gráfica, que propicia a visualização das predições e ações de controle realizadas. A plataforma de software Pavilion8®, é uma tecnologia de controle preditivo MPC, considerada uma camada de inteligência sobre ou acima de sistemas de automação básicos (PID).

A tecnologia de controle Pavilion8® disponibiliza as soluções de controle e otimização de acordo com as especificidades do processo. Dentro das funcionalidades para o controle preditivo da tecnologia Pavilion8® MPC, é prevista a avaliação contínua dos dados operacionais atuais e previstos.

Com base nos dados atuais e previsto e realizada a comparação dos resultados desejados (função objetiva) e calculado novos alvos de controle de maneira a reduzir a variabilidade no processo.

A tecnologia da Rockwell Automation MPC, utiliza recursos de modelagem híbrida, que permite, que cada modelo incorpore todo o conhecimento disponível sobre a dinâmica do processo, desta maneira pode-se disponibilizar modelos mais precisos.

O Pavilion8®, fornece um algoritmo que é capaz de manipular simultaneamente processos não lineares e lineares. De acordo com Figura 119 é possível observar a estrutura da equação que minimiza a função custo. O algoritmo calcula o horizonte de controle para manipulação das entradas do processo. As variáveis controladas (CV) são objetivo do controle ou restrições. No algoritmo do MPC Pavilion8® é previsto a entrada para perturbações medidas que podem eventualmente, afetar as variáveis controladas.

Por fim, as variáveis manipuladas (MV) podem gerar *set-point* para o controle PID ou as saídas podem atender a função objetivo. A frequência de execução do algoritmo é ajustável, o valor mínimo é de 0.5 segundos, este ajuste deve ser realizado em conformidade com as características e complexidade do processo ou planta.

Figura 119 - O Algoritmo da Função minimização custo – Pavilion8® - Rockwell Automation.

Fonte:(ROCKWELL AUTOMATION, 2015).

O controlador MPC Rockwell disponibiliza métricas de desempenho, através da monitoração contínua e indicadores-chave, como utilização, tempo em restrições e desvio do alvo. Essas métricas permitem medir o desempenho do controle preditivo.

A modelagem híbrida, pode ser baseada em dados empíricos, equações de relacionadas com os princípios físicos do processo, conhecimento do operador. Outra funcionalidade é a identificação do modelo através de redes neurais com ganho restrito de maneira garantir a precisão do modelo. O controle preditivo MPC da Rockwell, incorpora dinâmicas de processo tais como: tempo morto, constantes de tempo e ganhos em regime estacionário. A representação do modelo da dinâmica do processo é do tipo paramétrico, com entrada para perturbações ou distúrbios medidos, entradas das variáveis manipuladas e controladas.

O algoritmo utilizado para execução do controlador tem estrutura compacta e computacionalmente eficiente em função da redução de complexidade do modelo, sem sacrificar a precisão (HORN, 2009). O sistema Pavilion8® mantém um histórico contextual de ações de controle e trajetórias do controlador que são métricas de desempenho do controlador, incorporadas que medem a utilização, tempo em restrições e erro de alvos. Na Figura 120 é mostrada a arquitetura do MPC Pavilion8®, com os componentes da solução para controle preditivo.

Figura 120- Arquitetura do MPC Pavilion8® - Rockwell Automation.

Fonte:(ROCKWELL, 2012).

O software Pavilion8® disponibiliza um conjunto de módulos com interfaces, proporcionando ao projetista: um ambiente para o desenvolvimento do modelo da dinâmica do processo; parametrização; e implementação de controladores e analisadores virtuais.

As funcionalidades do ambiente de identificação de modelos são supridas pelo módulo *Model Builder* do Pavilion8®.

A estrutura interna do modelo da dinâmica de processo utilizada pelo Pavilion8® é o modelo do tipo ARX (AutoRegressive with *eXogenous* inputs), a qual embora ofereça pouco grau de liberdade, consegue representar satisfatoriamente os modelos no estado estacionários e dinâmico, mas não admite modelo de perturbações não medidas. Como reflexo imediato das limitações no grau de liberdade maior, a modelagem das propriedades relacionadas com distúrbios de processo fica bastante prejudicada ou mesmo impossibilitada (AGUIRRE, 2004).

Poucos controladores comerciais explicitam através de documentação técnica, a estrutura do modelo que é incorporada ou usada pelo algoritmo de predição, isto é, os modelos internos (ARX, ARMAX, BJ, etc). As informações disponíveis, geralmente, estão relacionadas com o desempenho do controlador, tipo de entradas (perturbações medidas, ruído de processo), ferramentas para a identificação, parametrização e sintonia, desenvolvimento de controladores e analisadores virtuais.

B.VIII - ASPEN DMC3™ CONTROLE PREDITIVO

O Controlador preditivo Aspen DMC3™, dispõe de um algoritmo de controle robusto que consegue lidar com a incompatibilidade de modelos. O controlador Aspen DMC3™ utiliza o algoritmo da programação linear para selecionar o conjunto de restrições ideais e compatíveis com a rentabilidade produtiva do processo.

A maioria das aplicações de controle avançado contém de duas a três vezes mais variáveis controladas, o que pode levar a várias combinações possíveis de restrições. Somente um destes conjunto de restrições, terá a maior rentabilidade. Neste caso, o algoritmo da DMC3™, utilizará o algoritmo LP para localizar ou encontrar o conjunto de restrições onde todas as variáveis controladas (CV), estão dentro dos seus limites de segurança operacional, maximizando a rentabilidade do processo (MARCHIONNA, 2017).

O fabricante destaca que, em qualquer formulação do MPC, uma abordagem padrão de programação linear (LP) para otimização, pode tornar o desempenho do controlador sensível a erros de modelagem. O controlador preditivo DMC3™ resolve este problema utilizando método de colinearidade, isto é, elimina a incompatibilidade significativa de modelo identificados (MARCHIONNA, 2017).

Segundo fabricante Aspentech™, a maioria das aplicações de controle preditivo, tem algum grau de distúrbios ou perturbações não medidas, que eventualmente podem comprometer a estabilidade e desempenho da planta.

A incompatibilidade do modelo a rejeição de distúrbios não medidos, irá degradar significativamente o desempenho do controlador.

O algoritmo Aspen DMC3™, busca compatibilizar este cenário com um algoritmo que utiliza o fator de robustez (*RF- Robustness Factor*) com métrica que varia de 0 a 1. O fator de robustez tem como objetivo, atenuar os efeitos de perturbações ou distúrbios não medidos, erros de modelagem. Este fator é usado para otimizar a robustez do controlador, através da ativação das restrições e movimentos e direção da manipuladas e controladas. Como exemplo, para um fator de robustez (RF) 0,1, todos os graus de liberdade serão usados para conduzir as variáveis para restrições ativas. A arquitetura utilizada pelo controlador Aspen DMC3™, é do tipo cliente-servidor. Quando a aplicação está em modo on-line, isto é, controlador Aspen DMC3™ ativo, o fator robustez é acessível a partir do servidor Web de Interface Controle e Produção (PCWS - *Process Control Web Server*).

Este fator poderá ser utilizado somente no modo de controle. Durante a simulação da solução de controle, o fator de robustez está disponível para utilização, de maneira a permitir que o projetista possa ajustar a melhor robustez do controlador.

O sistema Aspen DMC3™, prove funcionalidade de sintonia ou calibração do modelo ou re-sintonia para teste de novos cenários (SINGH; REIS, 2015). As principais funcionalidades disponibilizadas pelo sistema Aspen DMC3™, são:

1. Aprendizado de máquina no desenvolvimento do controlador, através de dados históricos;
2. Seleção de variáveis e restrições para desenvolvimento do controlador através de mineração de dados,
3. Desenvolvimento de controlador MPC não linear;
4. Modelagem incorporada na solução MPC;
5. Otimização dinâmica da planta (*Plant Wide*);
6. Integração de modelos dinâmicos rigorosos no MPC;
7. Hospedagem em nuvem de aplicativos de gerenciamento de operações;
8. Resolução da função custo através de algoritmo mínimos quadrados (QP);
9. Manutenção preventiva, de maneira a manter a maximização dos benefícios de controlabilidade da planta;
10. Teste de identificação de modelo em malha fechada;
11. Geração de modelos para análise de qualidade de performance;
12. Ambiente de desenvolvimento interativo (Windows).

A estrutura utilizada no Aspen DMC3™, para representar o modelo de processo é matriz dinâmica linear.

No ano de 1996, a AspenTech lançou o seu primeiro software comercial de controle preditivo MPC, desde então, vem aprimorando o seu produto através melhoria das ferramentas de identificação, melhoria da qualidade dos modelos da dinâmica do processo e função custo (MARCHIONNA, 2017). A Figura 121 mostra na linha do tempo, a evolução da tecnologia da AspenTech MPC.

Figura 121 – Evolução da Inovação do Controlador Aspen MPC.

Fonte: (KALAFATIS; CAMPBELL, 2017).

B.IX - CONSIDERAÇÕES SOBRE MPC COMERCIAIS

A tecnologia MPC, vem se tornando cada vez mais utilizada, em processos industriais, em decorrência do potencial de resolução de problemas de controle para sistemas complexos, onde as não linearidades estão presentes na dinâmica, do processo.

Algumas questões relacionadas com a manutenção do modelo durante o ciclo de vida da aplicação, tem sido recursivamente utilizada por uma grande parte dos fornecedores, como um diferencial da ferramenta computacional para desenvolvimento do controle avançado (APC).

Todavia estes, não conseguiram tratar integralmente as situações onde há perturbações ou distúrbios não medidos, inerentes ao modelo da dinâmica do processo, isto é, casos em que identificar modelos sem ausência de perturbações não mensuradas são impossíveis.

Atualmente, observa-se que, os usuários das soluções para controle preditivo estão, interessados em ferramentas que disponibilizem interfaces amigáveis ou intuitivas para a identificação de modelos, flexibilidade para seleção de estruturas de modelos, comissionamento, monitoramento e automação da manutenção em sistemas de controle preditivo multivariável.

O monitoramento contínuo de desempenho e a identificação automatizada de modelos são, algumas das novas exigências do projetista e usuários de sistema de controle, consumidor principal desta tecnologia (MICHAEL *et al.*, 2015). Michael *et al.* (2015), afirma que a uma grande aceitação do controle preditivo para aplicação na indústria, sendo que a principal expectativa do usuário desta tecnologia, é as melhorias nas interfaces que disponibilizem facilidades para desenvolvimento dos algoritmos e modelos da dinâmica, e que propiciar uma interação de maneira intuitiva entre as funcionalidades do controle e os operadores do processo.

Apêndice C

C.I - OIL SHALE XISTO

As pesquisas experimentais sobre o processo de extração de óleo betuminoso de xisto, iniciou-se na década de 50, mais precisamente na cidade de Tremembé no estado de São Paulo. O termo internacionalmente aceito para a matéria-prima de origem mineral, utilizada no processo de conversão térmica da PETROBRAS, patenteado como processo PETROSIX®, identificam a localização de Oil shale-xisto, em torno de 27 países, com grande variação de qualidade, quantidade e origem (CRAWFORD; KILLEN, 2010). Trata-se de uma rocha sedimentar, isto é, na matriz da rocha existe a presença de matéria orgânica. A matéria orgânica chamada querogênio, classificado como precursor do petróleo, isto é, uma forma imatura do petróleo. Todavia, através do processo de aquecimento e hidrogenação, o querogênio pode gerar óleo cru sintético (ABOLO *et al.*, 2014).

De acordo com Abolo *et al.* (2014), a definição do querogênio foi estabelecida em 1981, pelo Painel das Nações Unidas para Xistos e Areis Betuminosas (United Nations Oil Shale and Tar Sands Panel). O xisto é definido como uma rocha sedimentar que contém matéria orgânica sólida e combustível, chamada comumente como querogênio, praticamente insolúvel em solventes de petróleo (MALINOSKI, 2012).

O Brasil tem se destacado, pelo fato de possuir patente mundial, relacionado com a tecnologia para exploração do xisto, através de um processo de modo contínuo. Esta tecnologia começou a ser desenvolvida, por pesquisadores da PETROBRAS em 1949. Nesta época o governo federal, através de um decreto, oficializou a criação do grupo de pesquisa, para investigar a viabilidade econômica e o potencial de exploração dos produtos do xisto (NICOLINI, 2011).

No ano de 1950 foi criada a Comissão de Industrialização de Óleo de Xisto, tendo como objetivo, o estudo relativo a viabilidade econômica é técnica para exploração do xisto, através da construção de um usina protótipo localizada na cidade de Tremembé, em São Paulo (NICOLINI, 2011). Esta unidade tinha capacidade de produção de 10 mil barris por dia de óleo de xisto. Todavia, em decorrência do teor de umidade do xisto na região de Tremembé e a grande reserva encontrada na região do Estado do Paraná, decidiu-se pela construção da unidade de processamento de xisto nesta localidade. Entre os anos de 1957 e 1958 iniciou-se o desenvolvimento do processo de transformação de xisto. A partir do ano de 1972, a usina protótipo de Irati (UPI), localizada em São Mateus do Sul, Paraná, entrou em operação, sendo um marco na consolidação da tecnologia Petrobras (NICOLINI, 2011). Esta unidade está situada sobre a maior reserva de xisto do Brasil, a Formação Irati, a qual

engloba os estados de Mato Grosso do Sul, Goiás, São Paulo, Paraná, Santa Catarina e Rio Grande do Sul, transpondo a fronteira com o Uruguai (MALINOSKI, 2012).

A partir da extração da matéria orgânica do xisto são gerados subproduto sólido, conhecidos como xisto retornado, que representa de 80 a 90 % de todo o xisto bruto do processo de extração de petróleo. Na formação de Irati são encontradas duas camadas de rocha sedimentar de xisto, que são: a camada superior de xisto de 6,4 metros de espessura, com teor de óleo de 6,4 % e a camada inferior com espessura de 3,2 metros e teor de óleo de 9,1 %. Separando estas duas camadas é localizada uma superfície espessa de rocha carbonatada, também conhecida como calcário dolomítico (RIBAS, 2012). A Figura 122 mostra as respectivas camadas da formação de Irati, área de mineração de São Mateus do Sul, Estado do Paraná.

Figura 122. - Perfil geológico da mina de xisto betuminoso em São Mateus do Sul, Paraná.

Fonte: RIBAS (2012).

A partir do xisto betuminoso é possível gerar matéria orgânica. Para obtenção desta matéria orgânica, o xisto deve ser submetido a um incremento de temperatura. O processo responsável por esta conversão ou extração dos compostos do xisto, é conhecido como retortagem, ou seja, transforma esta matéria em óleo, além de outros derivados de petróleo economicamente viáveis, conforme destacam Jiang *et al.* (2007).

O Brasil é considerado o segundo país com maior volume mundial de xisto. Na formação de Irati estima-se reservas equivalentes a 1,9 bilhão de barris de óleo, 25 milhões de toneladas de gás liquefeito, 68 bilhões de metros cúbicos de gás combustível e 48 milhões de toneladas de enxofre (NUNES, 2013).

C.II - SISTEMA DE TRATAMENTO DE MINÉRIO

O processo PETROSIX® foi desenvolvido para a conversão do xisto em óleo, gás e subprodutos. Todavia, para que o reator, conhecido como retorta, possa processar a carga de xisto, é necessário que o material esteja adequado em relação a dimensões geométricas, ou seja, tamanho, teor de umidade, concentração de óleo, entre outros. Para atender as características relacionadas com as propriedades composição de teor óleo e dimensões geométricas, o xisto extraído da cava da mina deverá passar por um processo de tratamento de minério. A unidade de tratamento de minério ou mineração de xisto visa promover a extração e o processamento da rocha de xisto. A tecnologia usada para a extração do xisto é o método de lavra em tiras paralelas. As tiras ou lances de mina são em torno de 25 metros de largura e 2.500 metros de comprimento.

No método de extração em tiras, as duas camadas de minério, xisto superior e xisto inferior, são descobertas por uma escavadeira de caçamba de arrasto (*dragline*) com capacidade de aproximadamente 900m³/h, de acordo com as condições climáticas diárias. Este equipamento é responsável por 90% do total da descoberta do xisto na mina, quantidade necessária para atender a demanda do processo da PETROSIX®. É importante pontuar que, o método utilizado para mineração de xisto é considerado sustentável em razão das atividades de recuperação das áreas mineradas, que ocorre de forma concomitante com as atividades de frente de lavra ou extração do xisto (FILHO, 2017). Na Figura 123 é disponibilizada a imagem da cava da mina, onde é possível visualizar, a disposição da frente de lavra através do método de extração em tiras.

Figura 123 – Mineração de xisto pelo método em tiras.

Fonte: Filho, (2017).

Conforme destacado anteriormente, uma das funções da unidade de tratamento de mineiro é a realização de ajustes granulométricos na rocha xisto, para posterior envio a unidade de produção (FILHO, 2017). A Figura 124 mostra a imagem do xisto lavrado, formação de Irati.

Figura 124 - Minério de xisto - Formação de Irati.

Fonte: Autor.

A unidade de mineração de xisto é composta por duas unidades: a unidade frente de lavra, responsável pela extração do xisto, e a unidade tratamento de minérios, onde ocorrem todos os ajustes dimensionais do minério de xisto. A unidade de mineração é responsável por produzir cerca de 2,2 milhões de toneladas de minério de xisto por ano (SANTOS, 2009). O processo de mineração inicia-se com a operação de descobertura das camadas de xisto, que consiste em retirar as camadas de capeamento e posicioná-los na cava da mina, liberando assim as camadas de minério para o desmonte de rochas, chamado de frente de lavra. O xisto é transportado por caminhões até o sistema de britagem primária. Após o processo de desmonte da rocha de xisto, o minério de xisto é transportado por correia transportadora para o sistema de peneiramento, britagens secundária e terciária. Esta unidade é composta por 3 britadores, com configurações construtivas que propiciam fracionar o xisto. Na Figura 125 se vê o mecanismo de britagem primária, secundária e terciária.

Figura 125 – Mecanismo de britagem primária.

Fonte: Autor.

Por fim, o xisto é enviado através de correias transportadora, para o processo de classificação, que realizado através do sistema de peneiramentos secundário e terciário, de maneira a entregá-lo para o processamento (retorta) na especificação desejada. A Figura 126 mostra o processo de tratamento do minério de xisto com as principais etapas do processo de classificação do xisto, conforme descrito no texto.

Figura 126 – Unidade de Tratamento de Minério, processo de classificação do xisto.

Fonte: Autor (P&D).

Todo o processo de lavra e tratamento do minério de xisto é gerido por padrões e procedimentos que têm como objetivo, atender com eficácia, as diretrizes normativas, relacionadas com a exploração e reconstituição de áreas mineradas. Em decorrência da implementação de programas de valorização e incentivo às iniciativas de proteção do meio ambiente, que contribuam para a promoção do desenvolvimento sustentável, a SIX foi reconhecida com o Prêmio Chico Mendes.

C.III - O PROCESSO PETROSIX®

Para o processo de conversão do xisto, é usado um reator químico, denominado retorta, este equipamento foi desenvolvido pela PETROBRAS. A retorta proporciona o contato direto entre o gás de processo e o xisto sólido. O xisto entra pela parte superior do reator e à medida que se desloca é submetido a um gradiente de temperatura, até atingir a temperatura de pirólise, onde ocorre a liberação dos compostos orgânicos do material. A matéria do xisto quando decomposta termicamente, fornece óleo, gás e água. Depois da retirada destes produtos, resta como resíduo um material constituído essencialmente de base mineral (xisto retornado) além de carbono, hidrogênio e enxofre, não decompostos e extraídos com os produtos durante a retortagem. A Figura 127 mostra a interface

de operação do reator (P&D) e na Figura 128 é possível visualizar o reator real (retorta), onde ocorrem as reações de pirólise, para extração do óleo de gás de processo.

Figura 127 – Retorta: reator de xisto, processo de pirólise.

Fonte: Autor (P&D).

Figura 128 – Retorta – Processamento de xisto.

Fonte: Autor

Por fim, após o xisto passar pelo mecanismo de descarga, é direcionado para os transportadores de pás, sendo então descartado para o silo de rejeito. Todos os fluxos de gases injetados na retorta, reciclo quente e frio, somam-se à produção dos gases de retortagem e são

retirados do interior da retorta por dois dutos de saída de gases, localizados acima do topo do leito de xisto, na região dos tubos de carga.

A determinação do rendimento da conversão do xisto pirobetuminoso em óleo, quando aquecido, é determinado por ensaio em laboratório utilizando o método Fischer. Os resultados deste ensaio, comparados com a análise da matéria orgânica da rocha original indicam que pode se obter 90% do óleo teórico contido no minério, utilizando-se aproximadamente 9,0% da massa do minério. Todavia, existem outras variáveis que podem influenciar no processo de conversão da matéria orgânica em óleo e gás. Estas variáveis são: temperatura, pressão, teor de umidade, níveis de concentração de material orgânico. Contudo, as variáveis interferentes, são monitoradas e controladas, através de ensaios laboratoriais, onde o período amostral é concomitante com o processamento de xisto no reator (retorta). O xisto é transportado por correias transportadoras desde o peneiramento final até o topo da retorta. A retorta é alimentada através da região de topo, em operação contínua. A Figura 129 mostra o topo do reator (Retorta), onde entra a carga de xisto. Existem um conjunto de equipamentos, que tem por função manter a alimentação constante do reator (alimentadores rotativos), mecanismos de selagem para evitar emissão de gases de processo para atmosférica e sistema de controle de nível de sólidos.

Figura 129 - Topo do reator, entrada de xisto para Processamento.

Fonte: Autor (P&D).

O mecanismo de selagem de topo do reator, tem como objetivo, evitar a contaminação do ar atmosférico com o gás de retortagem ou processo, bem como impedir a entrada de ar para o interior da moega de carga (região de topo da retorta).

O sistema de selagem baseia-se no princípio de injeção de um elemento inerte na região de maior restrição do alimentador rotativo, criando um diferencial de pressão suficiente para impedir a saída do gás de retortagem para a atmosfera, e a entrada de ar para o interior da moega. O gás inerte, injetado na calha intermediária do alimentador rotativo, divide-se em dois fluxos, sendo que um toma rumo ascendente, passando pelas folgas do módulo superior do alimentador rotativo, atingindo a calha de alimentação. O outro fluxo, descendente, passa pelas folgas do módulo inferior do alimentador rotativo, adentrando na moega e incorporando-se ao fluxo de gás de retortagem produzido na retorta (NUNES, 2013). Na parte inferior do reator é removido o xisto com baixo teor de matéria orgânica, porém ainda com uma concentração de compostos aromáticos e calor recuperado. O xisto retornado, é extraído pela parte inferior de retorta após passar por todas as fases do ciclo de pirólise. O xisto retornado também é chamado de xisto pirolisado. Neste resíduo é encontrada uma parcela ponderável do carbono, hidrogênio e enxofre originalmente contidos no xisto cru (NUNES, 2013). De acordo com a Figura 130, pode-se visualizar a parte inferior da Retorta, por onde é removido o xisto retornado. O xisto retornado retirado pelo fundo da retorta e retorna à cava da mina, para recompor a topografia do terreno após a operação de mineração.

Figura 130 – Parte inferior da retorta, onde é retirado o xisto retornado.

Fonte: Autor (P&D).

Os produtos obtidos a partir do processamento de xisto, também conhecido como retortagem são:

1. Óleo xisto é um dos principais componentes do processo de retortagem. Uma grande parcela do óleo é obtida em forma de neblina, coletado nos sistemas de ciclones e precipitadores. Uma outra parcela do óleo de xisto, sai do reator em forma de vapor e é recuperada em condensadores de borrifos. Contudo, uma parte do óleo retirado da retorta é, responsável por gerar frações mais leves, para posterior comercialização como: nafta para pool de gasolina, uma fração intermediária, comercializada como substituto do diesel em fornos e caldeiras, e uma fração mais pesada de óleo, comercializada como óleo combustível de baixa viscosidade e baixo teor de enxofre;
2. Gás de Pirólise ou Gás de Processo: É um produto obtido em estado gasoso, não condensável nos *aircoolers* e não retidos nos lavadores de gás com borrifos e que contém, como componentes principais, H_2S , H_2 , CH_4 e demais hidrocarbonetos leves até o pentano, além de quantidades menores de CO_2 e CO . A partir do gás de processo são extraídos o gás combustível, gás liquefeito de xisto, além de enxofre como subproduto;
3. Água de Retortagem: É a água recuperada no lavador de gases de borrifos e que contém dissolvidas algumas substâncias, entre as quais minerais extraídos do xisto, caracterizados como micronutrientes, fenóis, amônia e sulfetos.

No reator a rocha de xisto é submetida a temperaturas de aproximadamente $500^{\circ}C$, onde são pirolisadas (tratadas termicamente), fazendo com que a matéria orgânica nelas contida seja liberada sob a forma de óleo e gás (NUNES, 2013). Cabe destacar que, apenas com o incremento de temperatura, em atmosfera redutora, que efetivamente o xisto é processado, isto é, um folhelho pirobetuminoso produz óleo e gás. O xisto cru, depois de pesado e amostrado, entra pelo topo da retorta, onde é distribuído por um mecanismo anti-segregacional e desce, em sentido vertical, com velocidade controlada pelo mecanismo de descarga existente na base da retorta (SANTOS, 2009).

O calor para a pirólise é fornecido por uma corrente gasosa de elevada temperatura, que entra na zona de retortagem. Um fluxo de gás, aquecido a uma temperatura conveniente, entra na retorta através dos injetores de gás quente, de onde sobe trocando calor com o xisto que desce, de modo que o gás esfria à medida que sobe e o xisto aquece à medida que desce, atingindo a sua temperatura máxima na região dos injetores. À medida que o xisto se aquece, sofre o processo de secagem e de decomposição da matéria orgânica (pirólise), desprendendo água, óleo e gás de processo, que são arrastados pela corrente de gás ascendente de onde são recuperados posteriormente os diversos produtos do processo. Após essa recuperação, a corrente efluente da retorta vai para o compressor de

reciclo para aumentar sua pressão e passa então pelo aquecedor, onde recebe energia e segue para os injetores de gás quente, finalizando o ciclo. Todavia, uma outra parcela do óleo é coletada, no precipitador eletrostático e vaso condensador e separador de interface óleo e água.

Na Figura 131 é visto o P&D do precipitador eletrostático com o vaso coletor de óleo e separador de interface.

Figura 131 – Precipitador Eletrostático e vaso condensador e separador de interface óleo-agua.

Fonte: Autor (P&D).

As rochas pirobetuminosas, em sua maioria, são de baixo potencial de geração de óleo e gás, o que implica na mineração, tratamento e processamento de uma enorme quantidade de rocha para a geração significativa desses produtos. É importante pontuar que, como o xisto da Formação Irati, há uma presença de material inerte, este componente (argila, areia, etc) contribui para a geração de volumes até seis vezes maiores de movimentação de solo (empolamento), em relação ao próprio xisto (SANTOS, 2009).

C.IV - VARIÁVEIS OPERACIONAIS DO PROCESSO DE RETORTAGEM

As principais variáveis operacionais envolvidas no reator de processo são:

1. Temperatura de Pirólise;
2. Velocidade de Retortagem ou Tempo de Residência;
3. Temperatura do Topo do Leito;
4. Pressão no Topo do Leito;
5. Perda de Carga no Leito.

Em relação à temperatura de pirólise, esta é considerada a variável mais importante do processo PETROSIX®, uma vez que tem grande influência na produção de óleo e gás. A operação da retorta com temperatura de pirólise (resfriamento) superior ao valor previamente estabelecido, pode influenciar no aumento da produção de gás com a redução do óleo, enquanto, temperaturas de pirólise abaixo do patamar de pirólise, pressupõem maior quantidade de óleo e menor de gás produzidos. Considera-se como temperatura de retortagem as temperaturas acima de 300°C, sendo desejável que as temperaturas na região de pirólise, mantenham-se em um gradiente de 400 a 550°C, com temperaturas médias de 500°C.

A temperatura de pirólise é controlada, através da atuação nas malhas de controle de vazão de reciclo quente, temperatura do reciclo quente, vazão de xisto, velocidade de retortagem (vazão de carga de xisto) ou tempo de Residência. A velocidade de retortagem está diretamente relacionada com a vazão de xisto e ao tempo de residência do xisto no interior da retorta. O controle de velocidade de descarga do xisto, altera o tempo de residência, em uma velocidade baixa, por exemplo, o contato entre o xisto com o gás de processo quente e maior, e consequentemente, melhor a retortagem, além de garantir a condição termodinâmica e a cinética de reação para o querogênio (MALINOSKI, 2012).

A temperatura de topo do leito (xisto), interno da retorta, é uma das variáveis que influenciam a eficiência térmica do processo e no controle da condensação dos gases e vapores emanados, da reação de pirólise do xisto. Valores muito elevados na temperatura de topo exigem maior demanda térmica, entre outras inconveniências, diminuindo assim a eficiência do processo. Todavia, as temperaturas muito baixas no topo do leito favorecem a condensação dos produtos da retortagem, causando refluxo interno de óleo e vapor, o que provoca desequilíbrio no perfil de temperaturas da retorta e descontrole do processo, dificultando a operação do sistema em regime e favorecendo a formação de aglomerados no interior da retorta (NUNES, 2013). Os valores da temperatura de topo estão diretamente relacionados com o teor de óleo na carga, devendo-se operar na faixa de 160 a 220°C, de modo a evitar a condensação excessiva do óleo e vapor produzidos na pirólise do xisto (DE

MELO, 2013). Para controlar a temperatura de topo, pode-se atuar na descarga de xisto, na vazão de reciclo quente e na vazão de reciclo frio, sendo que a temperatura de topo também é afetada pela temperatura de pirólise, embora não seja usual esse tipo de controle. Aumentando-se a vazão de xisto, a temperatura de topo cai (MOTA, 2009).

As vazões de reciclo quente e de reciclo frio agem de forma diretamente proporcional na temperatura de topo uma vez que, aumentando-se uma das vazões, a temperatura aumenta. A Pressão no Topo do Leito, deve ser mantida baixa possível. De acordo com Nunes (2013), quanto maior a pressão no topo do leito, maior é a possibilidade de haver condensação em excesso, o que pode causar a diminuição da porosidade no leito e provocar o fenômeno de refluxo interno, formando então aglomerados no interior do leito.

As perdas de cargas no leito de xisto, é a diferença de pressão existente, entre a zona de pirólise e o topo do leito. Embora seja uma variável dependente, a perda de carga tem importância fundamental no processo, pois exige maior consumo de energia no compressor de gases para que seja vencida a restrição no leito de xisto (NUNES, 2013). Ainda sobre a perda de carga no leito, está diretamente relacionado com a distribuição granulométrica do xisto no leito, aos teores de óleo e unidade na carga e à velocidade no gás no leito, além de outras de menor influência, como o refluxo de líquidos no leito (MOTA, 2009).

Uma grande parte do conjunto de variáveis operacionais não medidas (densidade, viscosidade, intemperismo, pirólise, etc), são controladas através de métodos inferenciais. Esta é uma característica do processo PETROSIX® (Reator de Xisto, Precipitador Eletrostático, Ciclones, etc), isto é, todo o conjunto de reações e as correlações entre as variáveis não mensuradas, são detectadas através de métodos analíticos (MOTA, 2009).

C.V - COMPRESSOR AXIAL

O compressor axial é acionado por motor elétrico, com acoplamento composto de 6 estágios, constituídos de 6 rodas de palhetas móveis instalados no rotor, e outros 7 conjuntos de palhetas fixas no estator. As palhetas móveis, que giram juntamente com o rotor, têm a finalidade de impulsionar os gases de processo, enquanto que as palhetas fixas no estator controlam a vazão de gás. A sucção do compressor axial está conectada a saída do precipitador eletrostático e a descarga, está ligada a entrada do forno industrial petroquímico de 50MW (NUNES, 2013). Além de controlar a vazão de gás xisto, o compressor é responsável por manter a dinâmica ou circulação, pelas diversas etapas do processo produtivo. As Figura 132 e 133 mostram o compressor axial, descrito nesta subseção.

Figura 132 – Compressor axial, fabricante Sulzer.

Fonte: Autor (P&D).

Figura 133 – Compressor Axial Sulzer– responsável pela dinâmica do gás do processo.

Fonte: Autor.

Figura 134 - Processo Petrosix Forno Industrial e Retorta.

Fonte: Autor.

Apêndice D

D. I. CONTRIBUIÇÃO ACADÊMICA

Foi aceito e apresentado o trabalho: “*IDENTIFICATION OF THE DYNAMIC MODEL OF A PETROCHEMICAL FURNACE OF 50MW FOR IMPLEMENTATION OF MPC CONTROL*”, no IFAC – *International Federation of Automatic Control* (disponível em <https://www.sciencedirect.com/journal/ifac-papersonline/vol/52/issue/1>).