

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**METODOLOGIA NÃO INTRUSIVA PARA ESTIMAÇÃO DO
TEMPO MORTO EM SISTEMAS MONOVARIÁVEIS**

DISSERTAÇÃO DE MESTRADO

Caetano Bevilacqua Kichel

Porto Alegre

2017

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

METODOLOGIA NÃO INTRUSIVA PARA ESTIMAR TEMPO MORTO EM SISTEMAS MONOVARIÁVEIS

Caetano Bevilacqua Kichel

Dissertação de Mestrado apresentada como
requisito parcial para obtenção do título de
Mestre em Engenharia

Área de concentração:
Pesquisa e Desenvolvimento de Processos

Linha de Pesquisa:
Projeto, Simulação, Modelagem, Controle e
Otimização de Processos.

Orientadores:
Prof. Dr. Jorge Otávio Trierweiler

Profa. Dra. Viviane Botelho

Porto Alegre

2017

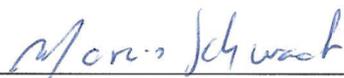
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

A Comissão Examinadora, abaixo assinada, aprova a Dissertação *Metodologia não Intrusiva para Estimar Tempo Morto em Sistemas Monovariáveis*, elaborada por Caetano Bevilacqua Kichel, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

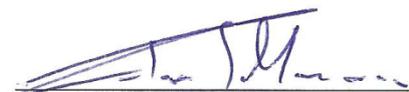
Comissão Examinadora:



Prof. Dr. Marcelo Escobar Aragão (FURG)



Prof. Dr. Márcio Schwaab (PPGEQ - UFRGS)



Prof. Dr. Celso Munaro (UFES)

Resumo

Dentre os fatores limitantes dos sistemas de controle, o tempo morto está entre os mais críticos e de difícil detecção sem testes intrusivos. O conhecimento do seu valor é essencial para a identificação de modelos e na auditoria de desempenho de sistemas de controle. Em virtude disto, o presente trabalho propõe uma metodologia eficaz para estimá-lo utilizando apenas dados históricos de processo em malha fechada. A principal vantagem frente a técnicas disponíveis na literatura é a não necessidade de testes intrusivos. A metodologia é baseada em um tratamento de sinal para remoção dos efeitos do distúrbio não medido e dos erros de modelo. O tratamento de sinal consiste na minimização das oscilações do sinal erro em malha aberta suavizado como função do tempo morto. Diversas formulações de função objetivo e procedimentos de suavização foram estudados visando facilitar a estimação do parâmetro. A qualidade da metodologia é ilustrada através de simulações em uma série de cenários, os quais simulam processos lineares de diferentes características sob o efeito de distúrbios distintos. A metodologia também é testada frente a estudo de casos com dados reais de processo industrial em malhas de nível e temperatura. Os resultados são comparados com métodos da literatura e demonstram que o método proposto foi eficaz na estimação do tempo morto para a maioria dos casos.

Palavras-chave: Estimação de Tempo Morto, Identificação em Malha fechada não intrusiva, Auditoria de desempenho de malhas de controle, Teoria de Controle.

Abstract

Among the limiting factors of control systems, the pure time delay is one of the most critical and difficult to estimate without an intrusive perturbation. The knowledge of its value is essential for model identification and control loop performance assessment. This work proposes a methodology to determine dead time using ordinary closed loop operating data. The main advantage over available techniques is the non-necessity of intrusive plant tests. The proposed approach is based on a signal processing for removing the effects of the unmeasured disturbances and the model-plant mismatches. The signal processing consists of the minimization of the oscillations of the smoothing open loop error as a function of the pure time delay. Several objective function formulations and smoothing procedures were studied in order to facilitate parameter estimation. The quality of the methodology is illustrated by simulations in a series of scenarios, which simulate linear processes of different characteristics under the effect of different disturbances. The methodology is also tested in case studies with real industrial process data. Results are compared to literature approaches and show the method was effective to estimate the pure time delay for most cases.

Keywords: Pure Time Delay estimation, non-intrusive closed loop identification, closed loop performance assessment.

“Se enxerguei mais longe, foi porque me apoiei sobre os ombros de gigantes”.
(Isaac Newton)

Agradecimentos

Agradeço a todos que contribuíram direta ou indiretamente para a realização desse trabalho, especialmente:

À Deus, que durante todos os momentos me deu forças para seguir em frente;

Aos meus pais, Waldacir Luiz Kichel e Cecília Maria Bevilacqua Kichel e avós Darci Bevilacqua e Sedalina Maria Bevilacqua por estarem sempre ao meu lado e que com amor sempre apoiaram e incentivaram minhas escolhas estimulando constantemente a minha educação. Aos demais familiares agradeço por estarem sempre torcendo pelo meu sucesso.

Aos meus orientadores, Prof. Dr. Jorge Otávio Trierweiler e Profa. Dra. Viviane R. Botelho por durante todos os momentos nesses 2 anos servirem como base para o desenvolvimento desse trabalho transmitindo seus conhecimentos, por todo apoio, disponibilidade, atenção e paciência.

À Petrobras e ANP pelo apoio financeiro as pesquisas desenvolvidas neste trabalho.

Ao grupo GIMSCOP e ao projeto BR-Toolkits que contribuíram para que esta tarefa se tornasse realidade.

À Universidade Federal do Rio Grande do Sul e ao Programa de Pós-Graduação em Engenharia Química pela oportunidade de realização desse trabalho.

SUMÁRIO

Capítulo 1 – Introdução	1
1.1 Motivação.....	1
1.2 Objetivos do Trabalho	6
1.3 Estrutura da dissertação	6
Capítulo 2 – Revisão Bibliográfica	7
2.1 Métodos de estimação de Tempo Morto por Aproximação	7
2.1.1 Métodos de aproximação no domínio do tempo.....	8
2.1.2 Métodos de aproximação no domínio da frequência	10
2.1.3 Métodos de aproximação no domínio de Laguerre	11
2.2 Métodos de Tempo Morto como Parâmetro Explícito	11
2.2.1 Métodos explícitos de um passo	11
2.2.2 Métodos explícitos de dois passos	13
2.2.3 Métodos de amostragem	13
2.3 Métodos de Área e Momento.....	13
2.3.1 Métodos de Área	13
2.3.2 Métodos dos Momentos	15
2.4 Métodos de Estatística de Elevada Ordem	17
2.5 Conclusão	17
Capítulo 3 – Metodologia Proposta.....	19
3.1 Ideia Básica	19
3.2 Obtenção do Modelo Inicial	22
3.3 Remoção do Efeito do Distúrbio não Medido do EMA	23
3.3.1 Uso da Derivada do Sinal	24
3.3.2 Ajuste Polinomial.....	25
3.3.3 Splines Suavizantes	27
3.4 Formulação da Função Objetivo	28
3.4.1 Minimização da variância do resíduo do erro em malha aberta.....	28
3.4.2 Minimização dos desvios do resíduo do erro em malha aberta	33
3.5 Otimização do Modelo Inicial.....	37
3.6 Definição do Tamanho da Janela de Dados	39
3.7 Fluxograma Esquemático	42
Capítulo 4 – Estudo de Casos - Simulados.....	44
4.1 Planta de Primeira Ordem – Tempo Morto Variável	44
4.1.1 Antes da Alteração do Tempo Morto	46
4.1.2 Após Alteração do Tempo Morto	51
4.2 Planta de Segunda Ordem – Tempo Morto Variável	54
4.2.1 Antes da Alteração do Tempo Morto	56
4.2.2 Após Alteração do Tempo Morto	60
4.3 Planta de Primeira Ordem Lenta – Tempo Morto Variável	63
4.3.1 Antes da Alteração do Tempo Morto	64
4.3.2 Após Alteração do Tempo Morto	68
4.4 Avaliação exaustiva da metodologia.....	71
4.5 Comparação com outros Métodos	78
4.6 Tanque – Tempo morto variável	85
Capítulo 5 – Estudo de Casos – Aplicação Industrial.....	92
5.1 Malha de Nível 1.....	93
5.2 Malha de Nível 2.....	96

5.3 Malha de Temperatura	99
Capítulo 6 – Conclusão e Trabalhos Futuros	104
Referências	106
Apêndice A – Resultados	110
A.1 Caso 4.4 SNR 5%.....	110
A.2 Caso 4.4 SNR 30%.....	112

LISTA DE FIGURAS

Figura 1.1: Diagrama de blocos do sistema em malha fechada.	2
Figura 1.2: Representação do sistema tanque PID.	2
Figura 1.3: Representação da mudança de <i>setpoint</i> do sistema tanque em malha fechada.	3
Figura 1.4: Representação da CV e <i>setpoint</i> do sistema tanque em malha fechada.	4
Figura 1.5: Estrutura genérica do Preditor de Smith. Fonte: K. Warwick (1988).	4
Figura 2.1: Estrutura de controle genérica do controlador de parâmetro adaptativo. Fonte: Isermann (2013).	8
Figura 2.2: Comparação entre as respostas impulso médias e do distúrbio em um estudo de caso. Fonte: Harrison & Qin (2012).	9
Figura 2.3: Determinação gráfica do modelo de dois parâmetros através do método das áreas. Fonte: Åström & Hägglund (1995).	14
Figura 2.4: Determinação gráfica do modelo de três parâmetros através do método das áreas. Fonte: Åström & Hägglund (1995).	15
Figura 2.5: Experimento de identificação de modelo FOPDT através do método dos momentos. Fonte: Ingimundarson & Hägglund (2000).	17
Figura 3.1: Diagrama esquemático de um sistema em malha fechada com discrepância de modelo e distúrbio não medido.	19
Figura 3.2: Variável controlada e variável manipulada.	20
Figura 3.3: Distúrbio não medido (a) e erro em malha aberta para modelos que diferem apenas no tempo morto (b).	21
Figura 3.4: Pilares da metodologia Proposta.	22
Figura 3.5: Comportamento do EMA e do EMA com tendência removida para modelos que diferem apenas no tempo morto.	23
Figura 3.6: Comportamento do EMA e do EMA com tendência removida para modelos que diferem apenas no tempo morto.	24
Figura 3.7: Curva de erro quadrático entre EMA_i e polinômio de ajuste versus ordem polinomial.	26
Figura 3.8: Comportamento do EMA e do respectivo polinômio de ordem 17.	26
Figura 3.9: Curva de erro quadrático entre EMA e <i>spline</i> de ajuste versus parâmetro de suavização.	27
Figura 3.10: Comportamento do EMA e da respectiva <i>spline</i> com parâmetro de suavização 0.1.	28
Figura 3.11: Função objetivo fazendo uso de derivação para remover tendência não linear.	29
Figura 3.12: Função objetivo fazendo uso de ajuste polinomial para remover tendência não linear.	30
Figura 3.13: Função objetivo versus o parâmetro de suavização polinomial e o tempo morto.	30
Figura 3.14: Comportamento típico da função objetivo quando o parâmetro de suavização escolhido não foi adequado.	31
Figura 3.15: Função objetivo de variância fazendo uso de <i>spline</i> para remover tendência não linear.	32
Figura 3.16: Função objetivo de variância versus o parâmetro de suavização de <i>spline</i> e o tempo morto.	32
Figura 3.17: Distribuição de probabilidade normal do resíduo do EMA.	33
Figura 3.18: Distribuição de probabilidade normal do resíduo do EMA e retas da regressão linear.	34

Figura 3.19: Função objetivo versus o parâmetro de suavização de <i>spline</i> e o tempo morto.	35
Figura 3.20: Função objetivo versus o parâmetro de suavização polinomial e o tempo morto.	35
Figura 3.21: Função objetivo fazendo uso de <i>spline</i> para remover tendência não linear..	36
Figura 3.22: Distribuição de probabilidade normal para parâmetro de suavização 0.7 e diferentes tempos mortos onde a curva verde representa o tempo morto correto.	36
Figura 3.23: Comportamento típico do EMA para um modelo desfavorável à estimação.	38
Figura 3.24: Comportamento típico da função objetivo versus o parâmetro de suavização e o tempo morto quando o modelo é desfavorável à estimação.	38
Figura 3.25: <i>Single Sided Amplitude Spectrum</i> do EMA para diferentes tempos mortos. .	41
Figura 3.26: Diferença entre os <i>Single Sided Amplitude Spectrum</i>	41
Figura 3.27: Fluxograma esquemático da metodologia proposta.	42
Figura 4.1: Sinal que representa o distúrbio não medido.....	45
Figura 4.2: Variável controlada e variável manipulada.....	45
Figura 4.3: Comportamento do EMA durante o intervalo da simulação para o modelo inicial para diferentes tempos mortos.	46
Figura 4.4: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.	47
Figura 4.5: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.....	47
Figura 4.6: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.	48
Figura 4.7: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.	49
Figura 4.8: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.....	49
Figura 4.9: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.	50
Figura 4.10: Comportamento do EMA e da <i>spline</i> suavizante com o tempo morto correto.	50
Figura 4.11: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.	51
Figura 4.12: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.....	52
Figura 4.13: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.	52
Figura 4.14: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.....	53
Figura 4.15: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.	53
Figura 4.16: Comportamento do EMA e da <i>spline</i> suavizante com o tempo morto correto.	54
Figura 4.17: Sinal que representa o distúrbio não medido.....	55
Figura 4.18: Variável controlada e variável manipulada.....	55
Figura 4.19: Comportamento do EMA durante o intervalo da simulação para os modelos iniciais para diferentes tempos mortos.....	56

Figura 4.20: Comportamento do EMA na janela de aplicação da metodologia para os modelos iniciais para diferentes tempos mortos.....	57
Figura 4.21: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 1.....	58
Figura 4.22: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo ordem 1.....	58
Figura 4.23: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 2.....	59
Figura 4.24: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo ordem 2.....	59
Figura 4.25: Comportamento do EMA na janela de aplicação da metodologia para os modelos iniciais para diferentes tempos mortos.....	60
Figura 4.26: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 1.....	61
Figura 4.27: Comportamento da função objetivo da variância versus parâmetro de suavização e tempo morto para modelo ordem 1.....	61
Figura 4.28: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 2.....	62
Figura 4.29: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo ordem 2.....	62
Figura 4.30: Sinal que representa o distúrbio não medido.....	63
Figura 4.31: Variável controlada e variável manipulada.....	64
Figura 4.32: Comportamento do EMA durante o intervalo da simulação para o modelo inicial para diferentes tempos mortos.	65
Figura 4.33: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.....	65
Figura 4.34: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo inicial.....	66
Figura 4.35: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo inicial.....	66
Figura 4.36: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.	67
Figura 4.37: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo.	67
Figura 4.38: Comportamento do EMA e da <i>spline</i> suavizante próximo do mínimo global da função objetivo.....	68
Figura 4.39: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.....	68
Figura 4.40: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo inicial.....	69
Figura 4.41: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para o modelo inicial.....	69
Figura 4.42: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.	70
Figura 4.43: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo.	70
Figura 4.44: : Comportamento do EMA e da <i>spline</i> suavizante próximo do mínimo global da função objetivo.....	71
Figura 4.45: Sinais utilizados para representar os diferentes distúrbios não medidos utilizados nas simulações.	73

Figura 4.46: Comportamento da função objetivo de variância para planta A, distúrbio d1 e ajuste 1.	75
Figura 4.47: Comportamento da função objetivo de variância para planta H, distúrbio d5 e ajuste 3.	75
Figura 4.48: Comportamento da função objetivo de variância para planta C, distúrbio d9 e ajuste 2.	76
Figura 4.49: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.	77
Figura 4.50: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.	77
Figura 4.51: Sinal que representa o distúrbio não medido.	78
Figura 4.52: Variável controlada e variável manipulada para os três subcasos.	79
Figura 4.53: Função objetivo de variância versus tempo morto para uma das janelas móveis.	80
Figura 4.54: Comportamento do EMA em todo intervalo de simulação para o modelo inicial para diferentes tempos mortos.	81
Figura 4.55: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.	81
Figura 4.56: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo inicial.	82
Figura 4.57: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para o modelo inicial.	82
Figura 4.58: Comportamento do EMA e da <i>spline</i> suavizante próximo do mínimo global da função objetivo.	83
Figura 4.59: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.	83
Figura 4.60: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo.	84
Figura 4.61: Diagrama de blocos do sistema em malha fechada.	85
Figura 4.62: Diagrama de blocos com as funções de transferência que descrevem o processo.	85
Figura 4.63: Sinal que representa o distúrbio não medido <i>Fin</i> ao longo da simulação. ...	86
Figura 4.64: Sinal que representa <i>Tin</i> ao longo da simulação.	87
Figura 4.65: Sinal que representa o distúrbio não medido inserido na saída do processo.	87
Figura 4.66: Variável controlada e variável manipulada para o estudo de caso 4.6.	88
Figura 4.67: Comportamento da função objetivo de coeficiente de determinação para o estudo de caso 4.6.	88
Figura 4.68: Comportamento da função objetivo de coeficiente de determinação para o estudo de caso 4.6.	89
Figura 4.69: Comportamento da função objetivo de coeficiente de determinação para o estudo de caso 4.6.	89
Figura 5.1: Variável manipulada, controlada e <i>setpoint</i> para o estudo de caso 5.1.	93
Figura 5.2: Intervalo de aplicação do método de identificação direta ARX.	93
Figura 5.3: Intervalo de aplicação do método proposto.	94
Figura 5.4: Ampliação da janela de mudança de <i>setpoint</i>	94

Figura 5.5: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo inicial.....	95
Figura 5.6: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo.	95
Figura 5.7: Variável manipulada, controlada e <i>setpoint</i> para o estudo de caso 5.2.....	96
Figura 5.8: Intervalo de aplicação do método de identificação direta ARX: primeira janela.	96
Figura 5.9: Intervalo de aplicação do método de identificação direta ARX: segunda janela.	97
Figura 5.10: Intervalo de aplicação do método proposto.....	97
Figura 5.11: Ampliação da janela de mudança de <i>setpoint</i>	98
Figura 5.12: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo inicial.....	98
Figura 5.13: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo.	99
Figura 5.14: Variável manipulada, controlada e <i>setpoint</i> para o estudo de caso 5.3.....	99
Figura 5.15: Intervalo de aplicação do método de identificação direta ARX.....	100
Figura 5.16: : Intervalo de aplicação do método proposto.....	101
Figura 5.17: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo inicial.....	101
Figura 5.18: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo.	102

LISTA DE TABELAS

Tabela 4.1: Modelos de Planta para o estudo de Caso 4.4.....	72
Tabela 4.2: Resultados da estimação do θ para Planta B com SNR 5%--Tempo Morto verdadeiro é de 15s.	73
Tabela 4.3: Resultados da estimação do θ para Planta C com SNR 5%--Tempo Morto verdadeiro é de 5s.	74
Tabela 4.4: Resultado da aplicação das 3 metodologias para os 3 subcasos de dados apresentados no estudo de caso 4.5.....	79

NOTAÇÃO E SIMBOLOGIA

$\text{Arg}(z)$	Argumento do número complexo z
ACO	<i>Ant Colony Optimization</i>
AMI	<i>Average Mutual Information</i>
ARMAX	<i>Autoregressive-Moving-Average with Exogenous Inputs Model</i>
ARX	<i>Autoregressive with Exogenous Inputs Model</i>
$C(s)$	Controlador
CV	Variável Controlada
EMA	Erro em Malha Aberta
F	Frequência
FIR	<i>Finite Impulse Response</i>
FPE	<i>Final Prediction Error</i>
GA	<i>Genetic Algorithm</i>
$G(s)$	Função de Transferência do Processo
$\hat{G}(s)$	Função de Transferência Estimada do Processo
$G_0(s)$	Função de Transferência do Modelo do Processo
$G_d(s)$	Função de Transferência do Modelo do Distúrbio
IMC	<i>Internal Model Control</i>
IV	<i>Instrumental Variable</i>
IVM	Índice de Variância Mínima
LS	<i>Least-Squares</i>
MIMO	<i>Multi-Input-Multi-Output</i>
MIT	<i>Mutual Information Theory</i>
MPC	<i>Model Predictive Control</i>
MV	Variável Manipulada
$n(t)$	Ruído de Medição
η	Índice de Harris
OE	<i>Output-Error Model</i>
PDF	<i>Probability Density Function</i>
PID	Controlador Proporcional-Integral-Derivativo
PEM	<i>Prediction Error Method</i>
PRBS	<i>Pseudorandom Binary Sequence</i>
PSO	<i>Particle Swarm Optimization</i>
R^2	Coefficiente de Determinação
S	Sinal suavizado
SISO	<i>Single-Input-Single-Output</i>

SNR	<i>Signal-to-Noise Ratio</i>
<i>sol</i>	Solução
<i>SQ</i>	Soma dos Quadrados
SVM	<i>Support Vector Machines</i>
t	Tempo
T	Período
TD	<i>Time Delay</i>
TS	Tempo de Amostragem
<i>u</i>	Variável de Entrada
<i>var</i>	Variância
<i>y</i>	Variável de Saída
\hat{y}	Variável de Saída Estimada pelo Modelo
y_d	Distúrbio não medido
y_{sim}	Saída simulada a partir de G_0 e das ações de controle u
y_{set}	<i>Setpoint</i>
$\hat{\beta}$	Vetor de parâmetros estimado
$\delta(t)$	Função Impulso
ΔG	Discrepância entre Modelo e Planta
θ	Tempo Morto
σ_{MV}^2	Variância Mínima
σ_y^2	Variância Atual da Variável Controlada
ζ	Vetor de Correlação
ω	Frequência
Φ	Espectro
zoh	<i>Zero-Order-Hold</i>

Capítulo 1 – Introdução

1.1 Motivação

Devido à alta competitividade presente no mercado há busca crescente por parte das indústrias pelo desenvolvimento de tecnologias que visam, além de aperfeiçoar a qualidade do produto final, reduzir impactos ambientais e tornar os processos produtivos mais rentáveis.

O advento das estratégias de controle automatizado foi um dos primeiros passos da engenharia que permitiu aumentar a eficiência operacional e reduzir a mão de obra não especializada, garantindo assim maiores lucros para as empresas. Considerado um marco na engenharia, contribuiu substancialmente para o desenvolvimento humano científico atual. Contudo, simultaneamente surge a necessidade de lidar com as dificuldades impostas pelo uso das técnicas de controle. Neste cenário, a pesquisa e o desenvolvimento de novas tecnologias são a principal forma de aprimorar as ferramentas atuais e solucionar as adversidades presentes no cotidiano das empresas.

Dentre os problemas mais comuns presentes nos sistemas de controle, o tempo morto está entre os mais críticos e de difícil detecção, sendo, portanto, objeto chave de discussão neste trabalho.

Tempo morto é a propriedade de um sistema físico em que a resposta para uma força aplicada sofre atraso no seu efeito (Shinskey 1979). Pode ser definido como o intervalo de tempo entre o começo do evento em um ponto no sistema e sua ação resultante em outro ponto (O'Dwyer n.d.). Sempre que material ou energia é transportada em um processo há tempo morto associado ao movimento (Dale E. Seborg, Duncan A. Mellichamp, Thomas F. Edgar, Francis J. Doyle 2010). Além do tempo morto presente no sistema, tempo morto aparente também pode ser oriundo de medições (processo de amostragem) ou através da identificação do sistema quando há a aproximação de um sistema de elevada ordem por um de menor ordem. (Ahmed et al. 2006). Ainda, tempo morto pode surgir a partir do acúmulo de pequenos atrasos provocados por sistemas de dinâmica simples conectados em série (Normey-Rico 2007).

Processos com tempo morto significativo são difíceis de serem controlados utilizando controladores retroalimentados (*feedback*) principalmente porque: (a) os efeitos dos distúrbios não medidos não são sentidos pelo sistema até que um considerado tempo tenha passado; (b) os efeitos das ações de controle levam certo tempo até que a variável controlada possa detectá-las; (c) a ação de controle que é aplicada baseada no erro atual tenta corrigir uma situação que se originou instantes de tempos atrás, o que frequentemente instabiliza o sistema. No domínio na frequência o tempo morto acrescenta um atraso adicional no sistema provocando uma queda na fase e na margem de ganho da função de transferência, que pode causar instabilidade (Normey-Rico 2007).

No controle de processos a estimação *on-line* do tempo morto é de grande interesse em virtude da manutenção da estabilidade das malhas de controle. Variações no tempo morto do sistema podem significar degradação do comportamento do processo ou forte influência de distúrbios não medidos, acarretando em impactos econômicos. Tomando como exemplo o sistema em malha fechada sujeito a um controlador PID, representado pela Figura 1.1 e Figura 1.2. O objetivo é controlar a temperatura de saída T_2 do tanque de volume V , através do calor Q do fluido de troca térmica. O sistema está sujeito a um tempo morto θ associado ao comprimento da tubulação L , com área de seção transversal A , representado pela relação:

$$\theta = \frac{AL}{F_{in}} \quad (1.1)$$

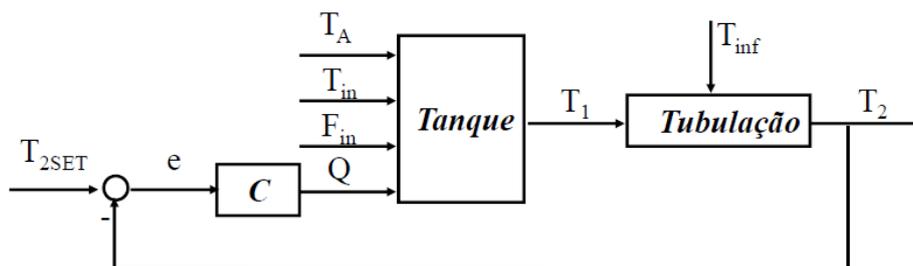


Figura 1.1: Diagrama de blocos do sistema em malha fechada.

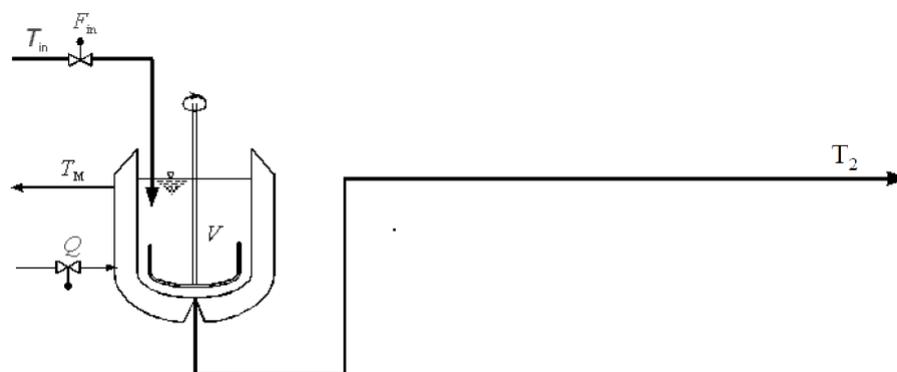


Figura 1.2: Representação do sistema tanque PID.

Onde T_{in} é a temperatura do fluido de entrada, T_{inf} a temperatura ambiente, F_{in} é a vazão do fluido de entrada e T_{2set} o sinal referência. Considerando que este sistema esteja sujeito a apenas dois distúrbios não medidos, T_{in} e F_{in} . A partir da equação 1.1 há alteração no tempo morto do sistema com a modificação de F_{in} . Sendo assim, se fosse possível obter o tempo morto do sistema de forma *on-line* e não intrusiva, seria possível estimar o distúrbio não medido F_{in} . Um estudo mais aprofundado deste sistema será feito no capítulo 4.

Tomando como exemplo o sistema da Figura 1.1. Considerando o tempo morto como 20 segundos. A partir de uma mudança no sinal referência (*setpoint*) do sistema em malha fechada seria possível obter uma resposta similar a da Figura 1.3. As técnicas de estimação de tempo morto presentes na literatura conseguem lidar facilmente com situações semelhantes, isto é, com sistemas fortemente excitados. Além disso, apenas com uma visualização da figura é possível estimar o tempo morto de 20 segundos, sem fazer uso de nenhuma técnica de estimação.

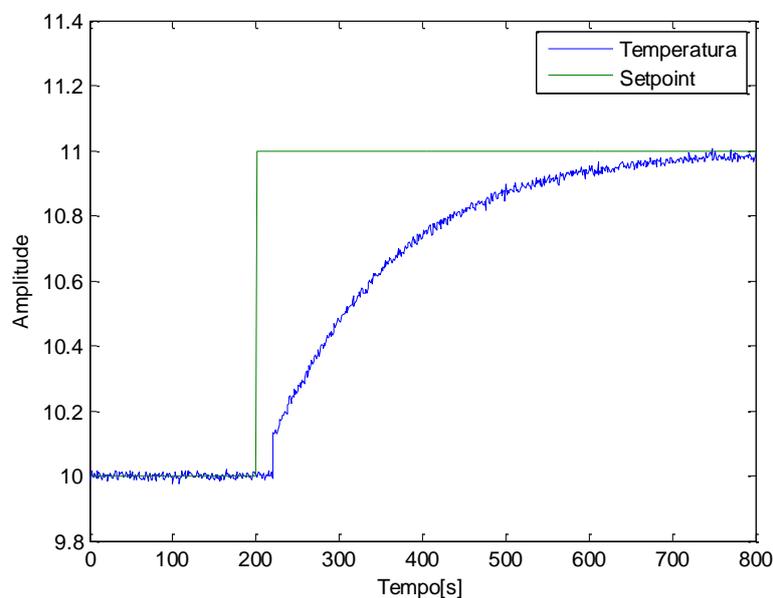


Figura 1.3: Representação da mudança de *setpoint* do sistema tanque em malha fechada.

Contudo, em sistemas sem qualquer tipo de excitação, nenhuma técnica presente na literatura seria capaz de avaliar o tempo morto. Como por exemplo, em uma situação representada pela Figura 1.4, onde o sistema está continuamente em operação com *setpoint* constante, situação muito comum na indústria de processos. O presente trabalho propõe uma metodologia capaz de lidar com este tipo de cenário.

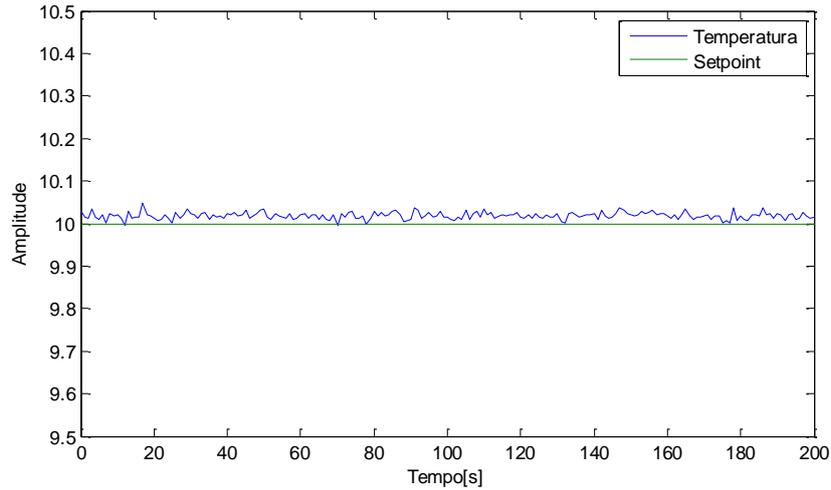


Figura 1.4: Representação da CV e *setpoint* do sistema tanque em malha fechada.

Ao longo dos anos surgiram técnicas que visavam compensar a influência do tempo morto no sistema como o controlador sugerido por Otto J. M. Smith (Smith 1957). O Preditor de Smith foi uma das primeiras estruturas de controle criadas para compensar tempo morto elevado de sistemas (controladores DTC, *dead time compensator*). É considerada uma estrutura de controle compensatória de tempo morto, e depende fortemente do modelo estimado da planta $\hat{G}(z)$ e do valor do tempo morto. Na Figura 1.5 é possível visualizar a estrutura genérica do Preditor de Smith (K. Warwick 1988).

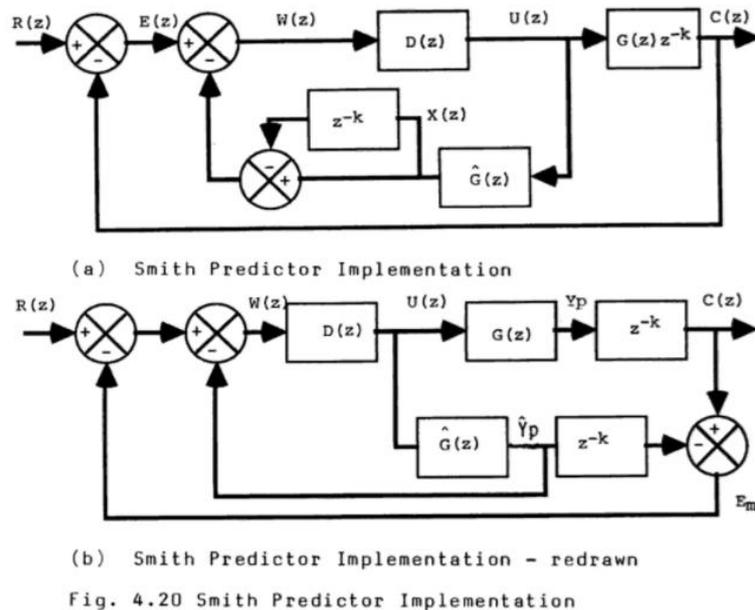


Figura 1.5: Estrutura genérica do Preditor de Smith. Fonte: K. Warwick (1988).

Onde $D(z)$ é o controlador a ser projetado, $G(z)$ a planta, $\hat{G}(z)$ o modelo da planta, z^{-k} o tempo morto, $R(z)$ o *setpoint*, $U(z)$ a ação de controle.

Devido a erros de modelagem o valor da saída estimada $\hat{Y}p$ nem sempre será igual ao de Yp . Desta forma o loop retroalimentado externo é implementado utilizando o sinal de erro Em para compensar o erro de modelo. Se o modelo fosse exatamente igual à planta, na ausência de distúrbios não medidos, então Em seria zero e a malha retroalimentada externa poderia ser removida.

O tempo morto presente no processo é um fator importante para o projeto dos sistemas de controle, uma vez que limita o seu desempenho. Por exemplo, o conhecimento da contribuição da fase oriunda do tempo morto na resposta no domínio da frequência de interesse é fundamental para o ajuste de algoritmos de controle.

Outra aplicação importante do conhecimento do tempo morto encontra-se na identificação e estimação de sistemas e modelos lineares, onde o tempo morto é uma variável crítica e faz-se necessária para a boa qualidade dos modelos estimados (Ljung 1987). Ainda, muitas técnicas de estimação de distúrbios não medidos dependem fortemente da influência deste parâmetro. Por fim, pode-se destacar a importância do conhecimento do tempo morto para técnicas de auditoria e desempenho de malhas de controle. Muitas destas técnicas dependem do conhecimento prévio do tempo morto, como o controlador/indicador de variância mínima, sugerido por Åström (1970).

O controlador de variância mínima foi sugerido por Karl J. Åström, na publicação de seu livro *Introduction to stochastic control theory* (Åström 1970). Nele são formuladas as bases da teoria de predição ótima de processos estacionários lineares, propondo então o controlador de variância mínima. Harris (1989) formulou um índice comparando a mínima variância teórica possível em um controlador com a variância real da saída da malha em questão. O Índice de Harris η ou índice de variância mínima (MVI) permitiu avaliação *on-line* de desempenho de controladores baseado apenas em dados rotineiros de processo e no tempo morto. Definido como a razão entre a variância mínima σ_{MV}^2 e a variância atual da variável controlada σ_y^2 , ou seja:

$$\eta = 1 - \frac{\sigma_{MV}^2}{\sigma_y^2} \quad (1.2)$$

O índice, varia entre 0 e 1, e representa o quão longe esta o controlador do melhor desempenho possível (i.e., menor variância). Valores próximos a 1 indicam deterioração do ajuste do controlador. Este é o principal índice de um conjunto chamado índices estocásticos (Bezergianni & Georgakis 2000), que permitem avaliação do desempenho utilizando conhecimento mínimo do processo. Com a proposta do índice de variância mínima surge a necessidade de estimar a variância mínima do processo. Desborough & Harris (1992) propuseram uma regressão linear simples para estimá-la. Mais tarde outros pesquisadores (Huang & Shah, 1999; Kempf, 2003; Tyler & Morari, 1996) propuseram metodologias mais aperfeiçoadas para estimar a variância mínima para controladores SISO, todas elas, utilizando apenas o tempo morto e dados de operação.

O índice de Harris é um dos principais exemplos de aplicação direta do conhecimento do tempo morto do sistema. A avaliação *on-line* do tempo morto permitiria avaliar o desempenho dos sistemas de controle de maneira frequente, sem a necessidade de testes intrusivos.

Embora o conhecimento do tempo morto seja de extrema importância, sua determinação não é possível de forma não intrusiva através de métodos disponíveis na literatura, existindo na maioria das técnicas, a necessidade de dados coletados a partir de pequenas perturbações no sistema. A característica intrusiva e as alterações na estrutura de controle propostas por estas técnicas podem limitar ou até mesmo inviabilizar a sua aplicação em sistemas de controle que já se encontram em operação. Atualmente não existem metodologias não intrusivas capazes de estimar o tempo morto fazendo uso apenas de dados históricos de processo.

1.2 Objetivos do Trabalho

Este trabalho propõe uma metodologia para estimar o tempo morto de maneira não intrusiva em sistemas monovariáveis através do uso de dados históricos do processo e dos parâmetros de sintonia do controlador. O método proposto é avaliado frente a cenários tipicamente encontrados na indústria. A principal contribuição do trabalho é permitir a estimação e o monitoramento do tempo morto de malhas de controle SISO (*single input single output*) de maneira não intrusiva.

1.3 Estrutura da dissertação

Este trabalho está dividido em 6 capítulos. O capítulo 1 descreve a motivação a respeito do tema, bem como os objetivos e a estrutura dos capítulos seguintes. O capítulo 2 trás um breve resumo dos principais métodos de estimação de tempo morto presentes na literatura. O capítulo 3 descreve a metodologia proposta para estimação de tempo morto. No capítulo 4 a metodologia é avaliada e testada frente a diferentes cenários que simulam processos de diferentes categorias sendo comparada com outros métodos da literatura. No capítulo 5 a metodologia é avaliada em uma aplicação industrial com dados reais de planta. O capítulo 6 apresenta as principais conclusões e possíveis aperfeiçoamentos do método sugeridos para trabalhos futuros.

Capítulo 2 – Revisão Bibliográfica

Este capítulo traz uma revisão bibliográfica sobre os principais tópicos relacionados ao desenvolvimento deste trabalho. Também é feito um breve resumo dos principais métodos de estimação do tempo morto encontrados na literatura científica.

Segundo Björklund (2003a) os problemas de estimação de tempo morto são classificados como ativos ou passivos (Hero et al. 1998, Quazi 1981). O problema ativo é utilizado para estimação de tempo morto em sistemas de controle retroalimentado (*feedback*), onde o sinal da entrada atual está correlacionado com o sinal da saída de instantes passados (malha fechada). O problema passivo é uma abordagem utilizada quando diferentes fontes de detecção estão presentes, sendo tipicamente utilizados em problemas associados na localização de fontes sonoras ou de radar (Houghton & Reeve 1997, Falk et al. 2002).

Considerando que o objetivo é a estimação do tempo morto em sistemas de controle de processos, neste trabalho será abordado o problema de estimação de tempo morto ativo.

Segundo Björklund (2003a) a literatura para estimação de tempo morto ativo se classifica em categorias de acordo com as premissas utilizadas na estimativa, sendo as quatro principais detalhadas nas subseções a seguir.

2.1 Métodos de estimação de Tempo Morto por Aproximação

Os sinais de entrada (u) e saída (y) são representados em uma base e o tempo morto é estimado a partir de uma aproximação entre os sinais e esta base. O tempo morto não é um parâmetro explícito. As bases podem ser de acordo com as subclasses detalhadas a seguir.

2.1.1 Métodos de aproximação no domínio do tempo

O sistema como um todo, incluindo o tempo morto é representado no domínio do tempo. A base é uma função impulso $\delta(t - t_n)$. A primeira etapa a ser considerada é a estimação dos coeficientes da resposta impulso. Isso pode ser feito através de uma análise de correlação cruzada entre os sinais de entrada u e saída y (Hero et al. 1998, Carter 1987) em um experimento em malha aberta, segundo descrito em Ljung (1987).

Uma alternativa seria estimar a resposta impulso através da estimativa de um modelo FIR (*Finite Impulse Response*) paramétrico (parâmetro explícito) minimizando o erro de predição através do *Prediction Error Method* (PEM), função objetivo descrita ainda nesta seção.

Contudo, muitas vezes, é necessário realizar um procedimento estatístico para reduzir o ruído de medição, como Gustafsson (2000) e Carlemalm et al. (1999). Nos método de aproximação no domínio do tempo o tempo morto estimado é o tempo em que a resposta impulso se torna não nula (Björklund 2003b, Carlemalm et al. 1999, Isaksson 1997, Kurz & Goedecke 1981). A principal desvantagem é a necessidade de uma fonte de excitação externa perturbando o sistema.

Em Kurz & Goedecke (1981) e Kurz (1979) modelos ARMAX são utilizados no lugar do FIR. O autor propõe o uso de um tipo específico de estrutura de controle, conhecido como controlador de parâmetro adaptativo (*parameter-adaptive control*), para estimar os parâmetros do modelo juntamente com o tempo morto do sistema de forma recursiva, sendo, portanto, uma estrutura de controle intrusiva. Uma versão genérica da estrutura de controle utilizada pode ser visualizada na Figura 2.1.

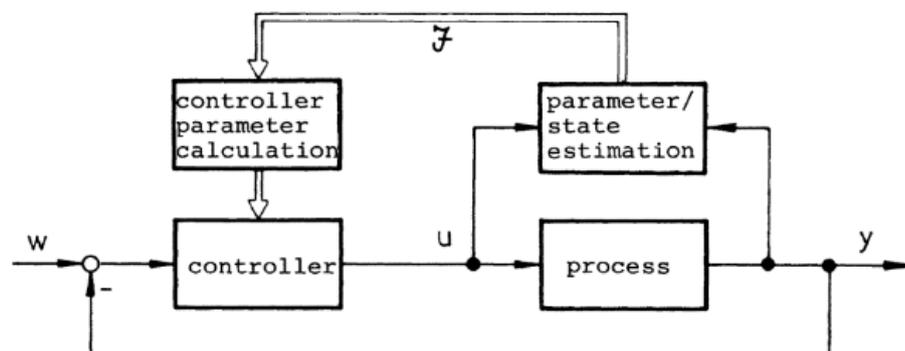
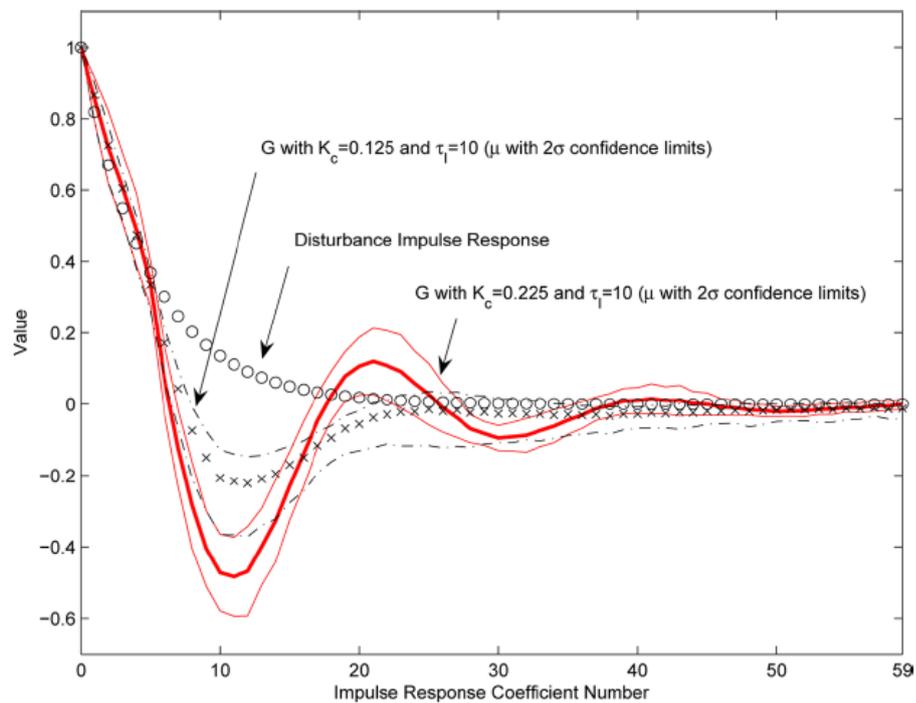


Figura 2.1: Estrutura de controle genérica do controlador de parâmetro adaptativo.

Fonte: Isermann (2013).

Harrison & Qin (2012) propõem um método para estimar o tempo morto de sistemas SISO em malha fechada para fins de monitoramento de desempenho. Ele necessita de modificações nos parâmetros de sintonia do controlador para obtenção de duas respostas impulso média, uma anterior e outra posterior à mudança dos parâmetros de sintonia. O método é aplicado em janelas móveis e para cada janela é encontrado uma

função de transferência em malha fechada como modelo ARMA, através da redução do erro de predição final FPE (*final prediction error*). As ordens do numerador dos modelos ARMA também são obtidas visando reduzir o FPE. Cada janela origina uma resposta impulso a partir do modelo e no final se calcula a resposta impulso média e seus intervalos de confiança. O trabalho se baseia no uso do princípio do *feedback* invariante em que os coeficientes da resposta impulso não mudam dentro da janela de tempo morto. O tempo morto estimado é o tempo em que os parâmetros de Markov das duas respostas impulso se tornam estatisticamente diferentes como pode ser visualizado na Figura 2.2. No exemplo em questão tanto o tempo morto estimado quanto o correto é 6 segundos, ou seja, no exato momento em que as respostas impulso se tornam diferentes.



Direct Comparison of Impulse Responses for $K_c = 0.225$ and $K_c = 0.125$.

Figura 2.2: Comparação entre as respostas impulso médias e do distúrbio em um estudo de caso. Fonte: Harrison & Qin (2012).

Babji & Tangirala (2009) propõe método para estimar o tempo morto em sistemas em malha fechada sem uso de perturbação externa, apenas com mudança de *setpoint*, utilizando a teoria da informação mútua (*mutual information theory* MIT). O método se baseia na estimativa de uma quantidade denominada informação mútua média (*average mutual information* AMI). Informação Mútua é a quantidade que mede a previsibilidade de uma variável quando informação sobre a outra é providenciada. Em termos de processo/sistema dinâmico significa a medida que determina a relação causa efeito entre entrada u e saída y . Estimar a AMI envolve estimar a distribuição de probabilidade conjunta dos sinais de entrada e saída, que é uma subdivisão dos métodos de correlação existentes, que apenas computam parte da distribuição conjunta (*joint distribution*). O tempo morto é estimado com uso da normalização da AMI com o valor máximo obtido, assim o tempo morto correspondente ao valor máximo de 1 é o valor estimado.

2.1.2 Métodos de aproximação no domínio da frequência

O sistema como um todo, incluindo o tempo morto é representado no domínio da frequência. A base consiste em um seno complexo $e^{i\omega t}$. O tempo morto é estimado a partir do deslocamento de fase do tempo morto de $e^{-i\omega\theta}$ no domínio da frequência (Isaksson et al. 2001, Isaksson 1997, Falk et al. 2002, Grennberg & Sandell 1994, Björklund 2003b, Houghton & Reeve 1997).

A primeira etapa a ser considerada é a estimação da resposta no domínio da frequência $\widehat{G}(e^{i\omega TS})$. Isso pode ser feito através de uma análise do espectro de correlação cruzada entre os sinais de entrada u e saída y em um experimento em malha aberta, segundo descreve Ljung (1987) através da seguinte relação:

$$\widehat{G}(e^{i\omega TS}) = \frac{\widehat{\Phi}_{yu}(\omega)}{\widehat{\Phi}_u(\omega)} \quad (2.1)$$

Onde $\widehat{\Phi}_{yu}(\omega)$ é a estimativa do espectro de correlação cruzada entre u e y e $\widehat{\Phi}_u(\omega)$ é a estimativa do espectro de autocorrelação de u e TS o tempo de amostragem. Ambos os espectros são estimados de diversas formas, normalmente se parte de um periodograma, posteriormente suavizado através de métodos descritos em Ljung (1987).

Alternativamente, estima-se um modelo paramétrico (parâmetro explícito) do sistema com tempo morto. Este modelo pode ser na forma FIR, ARX ou OE (*output error*) (Ljung 1987).

O tempo morto é estimado a partir da inclinação da fase de um espectro de correlação cruzada (*cross-spectrum*) no domínio da frequência:

Se $\widehat{G}(s)$ é um sistema linear contínuo e $\widehat{G}(i\omega)$ é a estimativa da resposta no domínio da frequência ω então:

$$\left. \frac{d}{d\omega} \arg \widehat{G}(i\omega) \right|_{\omega=0} = -\theta \quad (2.2)$$

Se $\widehat{G}(z)$ é um sistema linear discreto com tempo de amostragem TS e $\widehat{G}(e^{i\omega TS})$ é a estimativa da resposta no domínio da frequência então:

$$\left. \frac{d}{d\omega} \arg \widehat{G}(e^{i\omega TS}) \right|_{\omega=0} = -\theta \quad (2.3)$$

Note que a estimativa do tempo morto θ através dos métodos no domínio do tempo é análoga ao método do domínio da frequência.

2.1.3 Métodos de aproximação no domínio de Laguerre

O tempo morto é estimado a partir de uma relação entre os sinais de entrada e saída expressados nas funções de Laguerre (Fischer & Medvedev 1999, Fischer 1999).

Em Isaksson et al. (2001) o autor propõe método para estimar tempo morto em sistemas em malha fechada com a utilização de dados de processo, selecionados com uso de um critério proposto pelo autor, após mudança de *setpoint*. Em seguida estima-se um modelo de Laguerre (que pode ser considerado um filtro FIR), pois segundo o autor, este modelo pode representar melhor que ARX e OE sistemas onde o tempo morto explícito é desconhecido. O método estima o modelo e então o expande em fator de fase mínima e fator de fase não mínima. Posteriormente compara a fase não mínima deste com o modelo de Padé para estimar o tempo morto.

2.2 Métodos de Tempo Morto como Parâmetro Explícito

O tempo morto é um parâmetro explícito do modelo. Dividem-se em duas subclasses:

2.2.1 Métodos explícitos de um passo

O tempo morto e os parâmetros do modelo são estimados simultaneamente. Duas variantes são possíveis, na primeira o modelo e o tempo morto como parâmetro contínuo estimados em um modelo contínuo (tempo morto não é limitado a um múltiplo da amostragem) (Nagy & Ljung 1991, Ljung 1987). A segunda é o uso do modelo e tempo morto como parâmetros discretos estimados em um modelo discreto (Ljung 1987).

Métodos explícitos de um passo como parâmetro contínuo geralmente fazem uso de uma função objetivo no formato PEM (*prediction error method*) (Ljung 1987):

$$\hat{\beta} = \operatorname{argmin}_{\beta} \frac{1}{N} \sum_{t=1}^N \frac{1}{2} (y(t) - \hat{y}(t, \beta))^2 \quad (2.4)$$

Onde $\hat{\beta}$ é o vetor dos parâmetros do modelo a ser estimado, N o número de observações, $y(t)$ os dados observados e $\hat{y}(t)$ a saída predita pelo modelo.

Algumas variantes da função objetivo 2.4 são descritas em Ljung (1987), como por exemplo: a baseada no método dos mínimos quadrados (LS), mínimos quadrados regularizado (inclusão de variável adicional na função objetivo), o método da máxima verossimilhança (ML) e o critério de Akaike's (AIC).

A função objetivo 2.4 acima apresenta muitos mínimos locais (Ferretti et al. 1996, Nagy & Ljung 1991) logo depende fortemente do chute inicial.

Ainda, outra abordagem comum é a de correlação, descrita pela seguinte relação:

$$\hat{\beta} = \operatorname{sol}_{\beta} \left[\frac{1}{N} \sum_{t=1}^N \zeta(t, \beta) (y(t) - \hat{y}(t, \beta)) = 0 \right] \quad (2.5)$$

Onde ζ é o vetor de correlação e os seus elementos são chamados de variáveis instrumentais (Uma melhor descrição de como obter essas variáveis pode ser encontrada em Ljung (1987)). O objetivo da variável é diminuir a correlação do erro de predição futuro com os dados passados. Algumas variantes da equação são descritas no livro

como, por exemplo, a técnica da variável instrumental (IV). A escolha dos possíveis modelos a serem utilizados é descrita de forma detalhada em Ljung (1987). As funções objetivo descritas nesta subseção foram originalmente propostas para identificação de modelos a partir de experimentos em malha aberta ou em malha fechada com fonte de excitação externa na planta.

Em Wang & Zhang (2001) o autor sugere método de identificação de sistemas lineares contínuos a partir de perturbação degrau. Faz uso da técnica dos mínimos quadrados com variável instrumental (*instrumental variable least squares technique IV-LS*), onde uma matriz de variável é utilizada para representar o ruído de medição, no lugar dos mínimos quadrados (LS). Isso é feito para evitar problemas em estimar parâmetros com sistema ruidoso.

Mehrkanoon et al. (2016) propõe um método baseado em LS-SVM (*least squares support vector machines*) para identificar os estados e suas derivadas para depois converte-las em um problema de otimização algébrico. O tempo morto é estimado a partir da correlação cruzada entre a variável manipulada e a variável manipulada deslocada no tempo (estimada pela otimização). O método funciona sem perturbação externa no sistema, contudo faz uso de um modelo físico descrevendo o processo.

Ahmed et al. (2006) sugere um método que faz uso de um filtro linear para estimar o tempo morto e os outros parâmetros da função de transferência. Faz uso do método da variável instrumental (IV no lugar de LS) para eliminar bias de ruído branco de medição na etapa de otimização. Método é iterativo e necessita perturbação externa *piecewise constant* (perturbação estilo *PRBS*). Contudo, os parâmetros do filtro devem ser escolhidos de forma que ele possa cobrir banda de frequência do processo. Ainda, depende de chute inicial de tempo morto.

Nos métodos explícitos de um passo como parâmetro discreto geralmente requerem que o usuário saiba pelo menos o intervalo em que o tempo morto se encontra. Assim se limitam a tempos mortos como múltiplos da amostragem. Exemplo clássico são modelos ARX estimados com diferentes tempos mortos de maneira a selecionar o mais representativo com base em um critério de erro (Swanda 1999, Isaksson et al. 2001). Este critério de erro normalmente é o PEM. O tempo morto com menor função objetivo é o tempo morto estimado. O método é baseado no método de identificação direta em malha fechada de Ljung (1987), que faz uso diretamente das variáveis de entrada u e saída y para obter a estimativa do modelo da função de transferência da planta, ignorando o sinal referência (*setpoint*). De forma a reduzir a correlação entre os parâmetros do modelo e tornar a identificação viável geralmente é necessário o uso de dados obtidos através de fontes de excitação externa na planta (mudança de *setpoint*).

Oura et al. (1997) propõe um método para estimar a ordem e o tempo morto de sistemas em malha fechada. Ele faz uso de um ARX de elevada ordem para selecionar modelos candidatos para depois estimar a ordem e o tempo morto através do modelo DARX. Isso é feito, pois segundo o autor, o ARX consegue capturar a dinâmica do processo e do controlador, mas não serve para estimar a ordem correta porque mistura os efeitos, já o DARX captura características apenas do processo.

2.2.2 Métodos explícitos de dois passos

Alterna entre estimar o tempo morto e os outros parâmetros do modelo (Elnaggar et al. 1989, Pupeikis 1985).

2.2.3 Métodos de amostragem

Utiliza a amostragem do processo para derivar uma expressão para estimar o tempo morto. Métodos de amostragem se baseiam na premissa de que quando amostragens do tipo *zero-order-hold* (zoh) acontecem em um sistema contínuo há o surgimento de um zero no sistema discreto como resultado do tempo morto do processo (Åström & Wittenmark n.d., pag 40). Este tipo de estimativa de tempo morto depende que os zeros do sistema contínuo não sejam complexos e que o intervalo de amostragem seja pequeno o suficiente (Ferretti et al. 1991).

2.3 Métodos de Área e Momento

Estes métodos utilizam uma relação entre o tempo morto e a área sob ou sobre a curva da resposta degrau e certos momentos da resposta impulso na forma integral para estimar o tempo morto (Åström & Hägglund 1995, Björklund 2003c, Ingimundarson 2003, Wang & Zhang 2001).

2.3.1 Métodos de Área

Métodos de área normalmente fazem uso de uma perturbação degrau aplicada na planta em malha aberta para estimar o tempo morto a partir da integral no tempo, como em Åström & Hägglund (1995).

Considerando modelos de dois parâmetros como:

$$G(s) = \frac{K}{1+sT_{ar}} \quad (2.6)$$

Ou:

$$G(s) = \frac{a}{s\theta} e^{-\theta s} \quad (2.7)$$

Para modelos de dois parâmetros o tempo de residência T_{ar} é dado por:

$$T_{ar} = \frac{A_0}{K} \quad (2.8)$$

Onde K é o ganho estático e A_0 :

$$A_0 = \int_0^{\infty} \bar{y}(t) dt \quad (2.9)$$

Onde $y(t)$ é a resposta degrau e $\bar{y}(t) = y(\infty) - y(t)$. Sendo $y(\infty)$ e $u(\infty)$ os valores em estado estacionário após perturbação degrau na entrada. E K estimado como:

$$K = \frac{\bar{y}(0)}{\bar{u}(0)} \quad (2.10)$$

Onde $y(0)$ e $u(0)$ são os valores no instante da perturbação degrau.

Para um modelo simples de primeira ordem de dois parâmetros o tempo morto é facilmente identificado visualmente através da Figura 2.3. O tempo morto θ é a intersecção da tangente originada da maior inclinação da resposta degrau com a vertical.

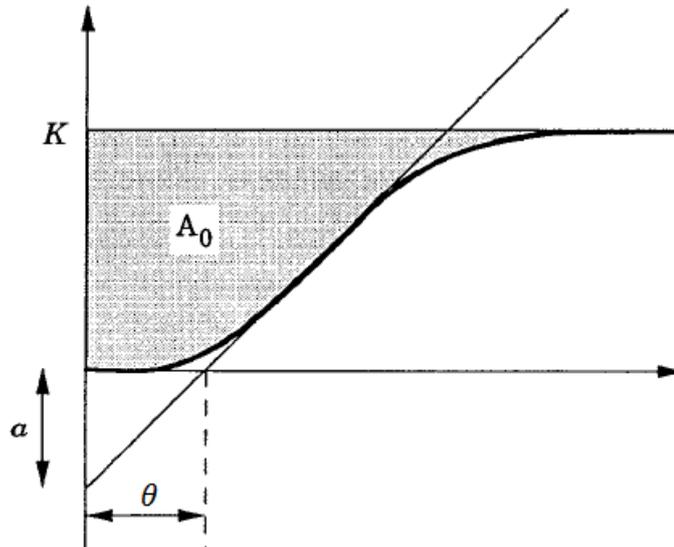


Figura 2.3: Determinação gráfica do modelo de dois parâmetros através do método das áreas. Fonte: Åström & Hägglund (1995).

Para modelos de primeira ordem com três parâmetros:

$$G(s) = \frac{K}{1+s\tau} e^{-\theta s} \quad (2.11)$$

O tempo de residência médio é a soma do tempo morto θ e a constante de tempo τ :

$$T_{ar} = \theta + \tau \quad (2.12)$$

Na Figura 2.4 é possível visualizar a determinação gráfica do modelo de três parâmetros. Onde τ estimado é distância entre AB, onde B é o tempo em que a resposta degrau atingiu $0.63K$. O tempo morto é a intersecção da tangente originada da maior inclinação da resposta degrau com a vertical. O ganho é determinado pela equação 2.10.

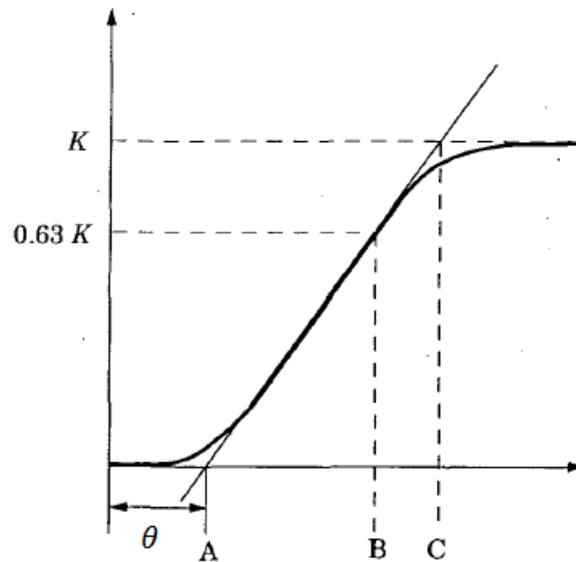


Figura 2.4: Determinação gráfica do modelo de três parâmetros através do método das áreas. Fonte: Åström & Häggglund (1995).

Para modelos de três parâmetros T_{ar} pode ser estimado da mesma forma que em 2.12. Definindo a relação:

$$A_1 = \int_0^{T_{ar}} \bar{y}(t) dt = K\tau e^{-1} \quad (2.13)$$

Tem-se que:

$$\tau = \frac{eA_1}{K} \quad (2.14)$$

$$\theta = T_{ar} - \tau = \frac{A_0}{K} - \frac{eA_1}{K} \quad (2.15)$$

2.3.2 Métodos dos Momentos

Os métodos dos momentos descrevem a resposta impulso do sistema como uma função densidade de probabilidade, integrando-a para obter a variável que representa o momento do sistema. O tempo morto é obtido a partir de uma relação semelhante aos métodos de área. Geralmente fazem uso de um experimento de resposta impulso em malha aberta como descrito em Åström & Häggglund (1995).

O tempo de residência médio para modelos de três parâmetros é descrito como:

$$T_{ar} = \frac{\int_0^{\infty} th(t) dt}{\int_0^{\infty} h(t) dt} \quad (2.16)$$

Onde $h(t)$ é a resposta impulso.

O ganho do sistema é estimado como:

$$K = G(0) = \int_0^{\infty} h(t) dt \quad (2.17)$$

A constante de tempo é dada por:

$$\tau^2 = \frac{\int_0^{\infty} t^2 h(t) dt}{\int_0^{\infty} h(t) dt} - T_{ar}^2 \quad (2.18)$$

O tempo morto estimado é dado por:

$$\theta = T_{ar} - \tau \quad (2.19)$$

O método também foi adaptado para qualquer tipo de perturbação (não apenas resposta impulso) em malha aberta desde que o sistema esteja inicialmente em estado estacionário. Ainda, pode ser utilizado em malha fechada com perturbação, segundo descrito em Ingimundarson & Hägglund (2000).

Ingimundarson & Hägglund (2000) propõe um método baseado no método dos momentos para sistema inicialmente em malha fechada em estado estacionário que se divide em duas etapas. Primeiro o tempo de residência médio ($T_{ar} = \theta + \tau$) e o ganho K são estimados com uma mudança no *setpoint* em malha fechada através da seguinte expressão (baseado no método dos momentos):

$$T_{ar} = \frac{\int_0^{\infty} \bar{y}(t) dt}{\bar{y}(0)} - \frac{\int_0^{\infty} \bar{u}(t) dt}{\bar{u}(0)} \quad (2.20)$$

Onde $\bar{u}(t) = u(\infty) - u(t)$, e $\bar{y}(t) = y(\infty) - y(t)$, sendo $y(\infty)$ e $u(\infty)$ os valores em estado estacionário após mudança de *setpoint*.

A segunda etapa consiste em estimar a constante de tempo τ a partir de um experimento em malha aberta com um sinal degrau ou rampa através da seguinte relação:

$$\tau = \frac{Ae^1}{hK} \quad (2.21)$$

Onde h é a amplitude da resposta degrau, A é a integral de $y(t)$ de 0 até T_{ar} e K é o ganho estimado através de:

$$K = \frac{\bar{y}(0)}{\bar{u}(0)} \quad (2.22)$$

Onde $y(0)$ e $u(0)$ são os valores no instante da mudança no *setpoint*.

A Figura 2.5 mostra um exemplo do procedimento de identificação proposto para estimação do modelo FOPDT (*first order plus dead time model*) com mudança no *setpoint* em malha fechada em t_b e experimento em malha aberta em t_f . Note que:

$$y_1 = \int_0^{\infty} \bar{y}(t) dt \quad (2.23)$$

$$u_1 = \int_0^{\infty} \bar{u}(t) dt \quad (2.24)$$

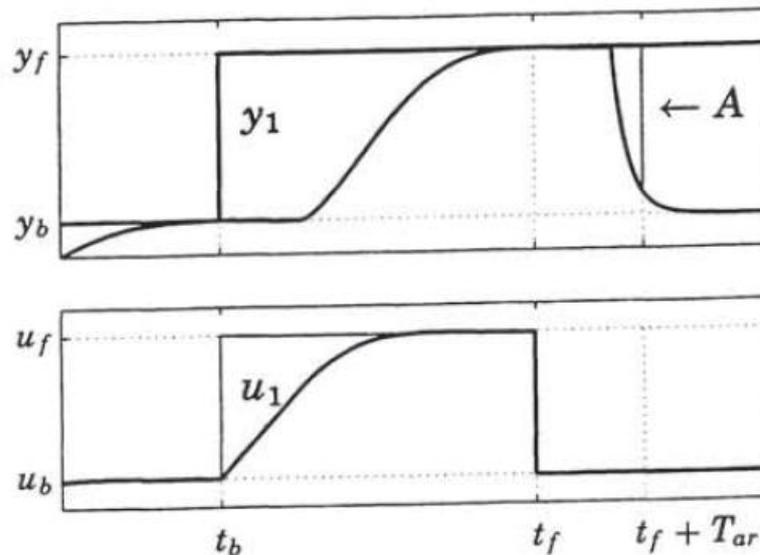


Figura 2.5: Experimento de identificação de modelo FOPDT através do método dos momentos. Fonte: Ingimundarson & Hägglund (2000).

O tempo morto é estimado pela relação:

$$\theta = T_{ar} - \tau \quad (2.25)$$

Ingimundarson (2003) propõe o método dos momentos para identificar modelos FOPDT em sua tese de doutorado, juntamente com aplicação direta em controladores do tipo compensador de tempo morto DTC (*dead time compensator*), que fazem uso de um modelo identificado do processo. Em sua tese também descreve metodologias para ajuste de controladores do tipo DTC, comparando-as com o controlador clássico PID (*proportional integral derivative controller*).

2.4 Métodos de Estatística de Elevada Ordem

Métodos de estatística de elevada ordem (*Higher-order statistics HOS*) (Nikias & Mendel 1993) baseiam-se em eliminar a presença do ruído de medição quando este possui função de densidade de probabilidade simétrica (*symmetric probability density function PDF*). Portanto fazem uso de métodos para discriminar entre sinais com função de probabilidade simétrica e não simétrica. São normalmente utilizados quando o sinal desejável e o indesejável diferem neste aspecto.

2.5 Conclusão

A grande maioria das técnicas presentes na literatura depende de experimentos em malha aberta ou a inserção de perturbações conhecidas na variável manipulada, ou até mesmo a utilização de estruturas de controle intrusivas, modificações na sintonia do controlador ou mudanças de *setpoint* em sistemas em malha fechada. Cada uma das metodologias descritas até então possui suas particularidades e apresenta uma série de aplicações, contudo, nenhuma foi capaz de estimar o tempo morto de forma não intrusiva. Desta forma, este estudo foi proposto em virtude da necessidade de uma metodologia que atenda este propósito.

Capítulo 3 – Metodologia Proposta

Neste capítulo é apresentada a metodologia para estimação do tempo morto proposta neste trabalho.

3.1 Ideia Básica

A Figura 3.1 ilustra um sistema de controle SISO, onde $C(s)$ é o controlador, $G_0(s)$ é o modelo identificado para o processo, $\Delta G(s)$ é a discrepância entre o modelo identificado e a planta real $G(s)$, y_{set} corresponde ao setpoint, u é a variável manipulada, y a variável medida, y_d é o distúrbio não medido e y_{sim} a saída simulada a partir de $G_0(s)$ e das ações de controle u :

$$y_{sim}(t) = G_0(s)u(t) \quad (3.1)$$

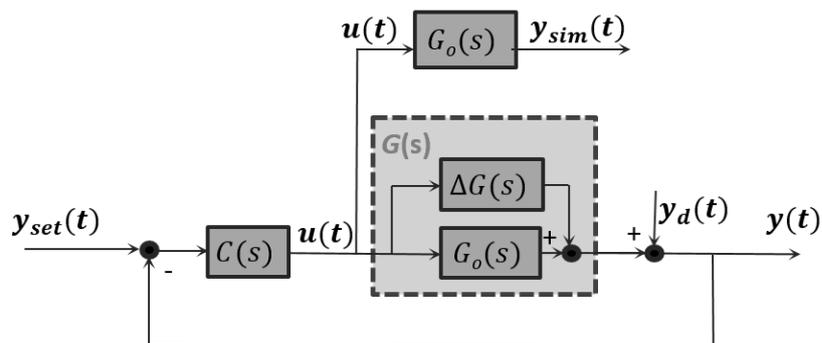


Figura 3.1: Diagrama esquemático de um sistema em malha fechada com discrepância de modelo e distúrbio não medido.

A partir das saídas medidas y e simuladas y_{sim} , o erro em malha aberta (EMA) é definido como:

$$EMA = y(t) - y_{sim}(t) \quad (3.2)$$

O erro em malha aberta é um sinal que captura simultaneamente os efeitos dos erros de modelagem $\Delta G(s)$ e do distúrbio não medido y_d , tendo em vista que y_{sim} é um sinal isento destes efeitos (observe que se o modelo fosse perfeitamente capaz de capturar o comportamento da planta e não existissem distúrbios, o EMA seria nulo). Dessa forma quanto maior for a similaridade entre G_0 e a planta real, menor será o efeito do erro de modelagem e, conseqüentemente, maior a fração do EMA que é proveniente do distúrbio não medido. Com base nesta premissa, a metodologia proposta está centrada em minimizar o efeito do erro de modelagem de forma que seja possível estimar o tempo morto do processo através do EMA.

Considerando como exemplo o processo de primeira ordem com tempo morto descrito pela equação 3.3, sob efeito de um controlador PID com ganho 0.13, constante de tempo integral 45 e constante de tempo derivativa 0.4. Na Figura 3.2 pode ser visualizada a variável controlada e manipulada para o exemplo.

$$G(s) = \frac{8e^{-5s}}{15s+1} \quad (3.3)$$

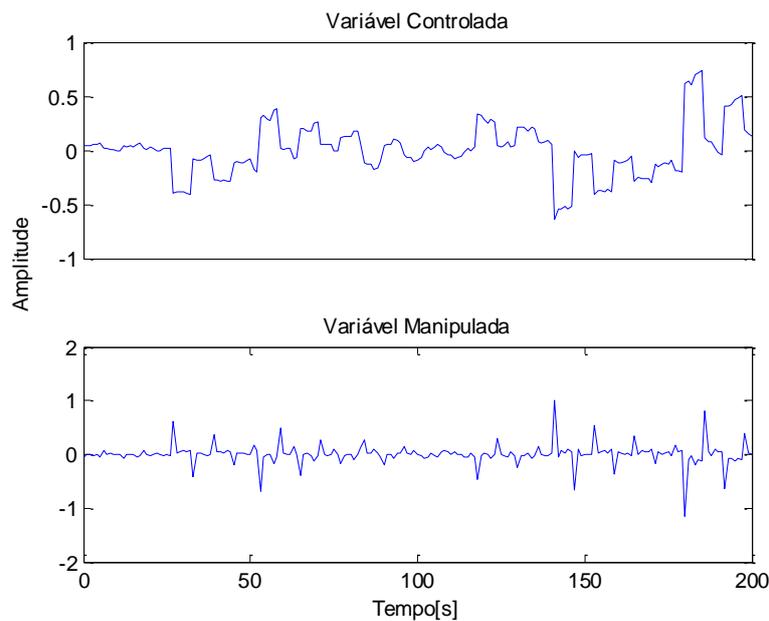


Figura 3.2: Variável controlada e variável manipulada.

Supondo, inicialmente, que um modelo $G_0(s)$ tenha sido perfeitamente projetado para este processo (i.e., modelo captura perfeitamente o comportamento do processo, sendo descrito pela equação 3.3) e que o sistema esteja sujeito a *setpoint* constante (zero) e ao distúrbio apresentado na Figura 3.3a. Se o EMA for avaliado, observa-se que o sinal obtido possui comportamento similar ao do distúrbio não medido. Supondo agora que existam discrepâncias entre a planta $G(s)$ e o modelo $G_0(s)$ apenas no tempo morto

θ (i.e, ganho e constante de tempo são iguais), neste caso, o comportamento do EMA para diferentes valores de θ é ilustrado na Figura 3.3b.

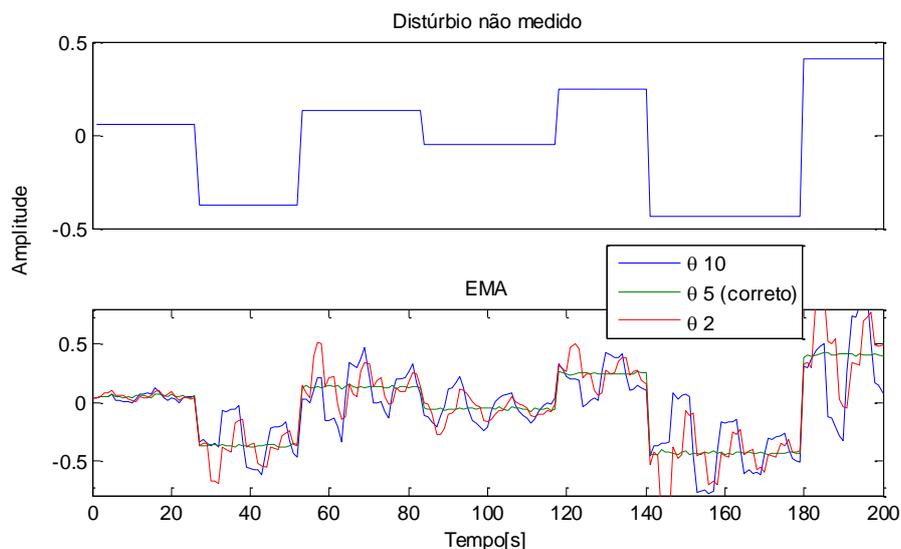


Figura 3.3: Distúrbio não medido (a) e erro em malha aberta para modelos que diferem apenas no tempo morto (b).

A Figura 3.3b mostra um conjunto de modelos que diferem apenas no tempo morto origina um conjunto de diferentes erros em malha aberta onde todos possuem em comum o sinal do distúrbio não medido. A única parte distinta do sinal é proveniente dos efeitos do erro de modelo, provocados pelo tempo morto. Ainda, percebe-se um acréscimo de oscilações no sinal quando o tempo morto do modelo difere do verdadeiro.

Assim, com base no que foi descrito, a metodologia proposta está centrada na formulação de um problema de otimização que busque a minimização das oscilações excessivas do sinal do EMA, onde a variável de decisão é o tempo morto. Diversas alternativas de função objetivo foram estudadas de maneira a mensurar as oscilações referentes ao parâmetro e serão detalhadas a seguir.

Conforme já mencionado, se fosse possível decompor o sinal do EMA, parte dele seria decorrente do erro de modelagem e outra parcela seria referente ao efeito do distúrbio não medido. Como o objetivo é avaliar apenas o efeito do parâmetro tempo morto, seria conveniente eliminar o efeito do distúrbio não medido. Se o sinal do distúrbio não medido fosse conhecido (i.e, medido) seria possível subtraí-lo diretamente do sinal do EMA e avaliar o efeito do tempo morto. Como não há conhecimento sobre o distúrbio não medido, a metodologia se propõe a remover o seu efeito do EMA através da remoção da tendência do sinal a ser utilizado no problema de otimização. Com isso, estima-se que a parcela remanescente do EMA seja predominantemente oriunda do erro de modelagem, melhorando assim a estimativa do tempo morto proveniente da otimização.

Sendo assim, a metodologia proposta é subdividida em três grandes pilares, ilustrados na Figura 3.4, as quais serão detalhadas nas próximas seções. Cabe salientar que todos estes pilares estão integralizados em um algoritmo, que será consolidado ao final deste capítulo.

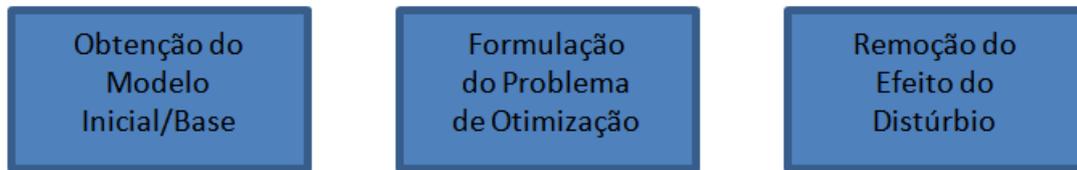


Figura 3.4: Pilares da metodologia Proposta.

3.2 Obtenção do Modelo Inicial

O modelo base/inicial serve para a geração do sinal do EMA. Durante o procedimento, todos os seus parâmetros serão mantidos fixos, exceto o tempo morto, que será a variável de decisão do problema de otimização. Não é necessário que este modelo represente com muita precisão o comportamento do processo real, mas deve apresentar certa similaridade, a fim de evitar erros em malha aberta demasiadamente elevados (i.e., a ponto de tornarem o EMA insensível ao efeito do tempo morto). Uma alternativa plausível é utilizar o modelo identificado para o processo (G_0) como modelo base.

Contudo, em sistemas com controladores PID, o modelo G_0 é quase sempre desconhecido. Desta forma, uma alternativa para se estimar um modelo inicial consiste no emprego dos parâmetros de sintonia do controlador.

Neste trabalho foi utilizado o método IMC de ajuste de controladores PID como base para a obtenção de um modelo inicial, conforme proposto por Lima (2016). A tabela completa que relaciona o ajuste do controlador com os parâmetros do modelo da planta pode ser encontrada em Seborg et. al. (2010).

Na metodologia proposta neste trabalho, considera-se conhecida a ordem da planta (primeira ou segunda ordem). Assim, para sistemas de primeira ordem, partindo dos parâmetros de sintonia do controlador (ganho proporcional K_c , constante de tempo integral τ_i e constante de tempo derivativa τ_d) na sua forma ideal, se busca o modelo de primeira ordem equivalente fazendo uso da seguinte equação da tabela IMC:

$$\tau = \tau_i \quad (3.4)$$

$$K = \frac{1}{K_c} \quad (3.5)$$

Onde K é o ganho do modelo e τ a constante de tempo.

Para sistemas de segunda ordem, a ideia é sempre obter um modelo de segunda ordem subamortecido equivalente. Isso porque sistemas subamortecidos possuem, em geral, maiores graus de liberdade para representar sistemas de segunda ordem. Sendo assim, partindo das equações 3.4 e 3.5 define-se a seguinte função de transferência de segunda ordem subamortecida:

$$\frac{Ke^{-\theta s}}{(\tau)^2 s^2 + (\tau)s + 1} \quad (3.6)$$

Cabe ressaltar que a metodologia proposta não depende fortemente do método aplicado para obtenção do modelo inicial, desta forma outras sistemáticas de ajuste podem ser empregadas.

3.3 Remoção do Efeito do Distúrbio não Medido do EMA

Conforme ilustrado na Figura 3.3, uma parcela significativa do erro em malha aberta se deve a presença do distúrbio não medido. Assim, de modo a deixar o sinal oriundo dos erros de modelagem mais evidente, é conveniente eliminar o efeito do distúrbio, uma vez que sem ele o efeito do tempo morto está diretamente associado às oscilações do sinal remanescente (considerando que o mesmo modelo base foi utilizado, exceto pela variação do tempo morto).

A metodologia proposta busca eliminar os efeitos do distúrbio não medido através da remoção da tendência não linear do sinal EMA. Isto pode ser visualizado através da Figura 3.5, que mostra os sinais do EMA após a remoção da tendência. Destaca-se que o modelo com o tempo morto correto tende a ter menor variância no sinal do EMA com tendência removida.

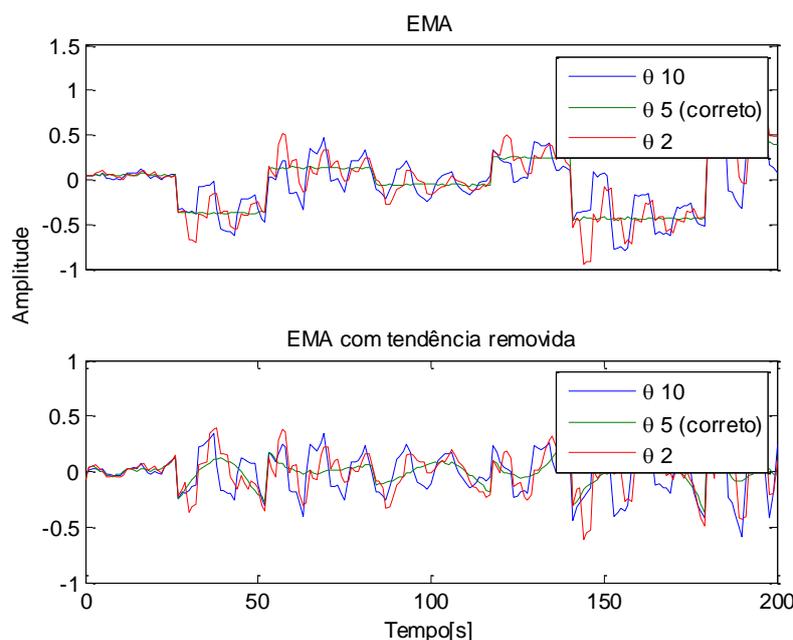


Figura 3.5: Comportamento do EMA e do EMA com tendência removida para modelos que diferem apenas no tempo morto.

Na Figura 3.6 é possível visualizar o efeito da remoção da tendência do EMA para um distúrbio não medido, com características senoidais. Neste caso a remoção da tendência deixa ainda mais evidente o efeito do tempo morto.

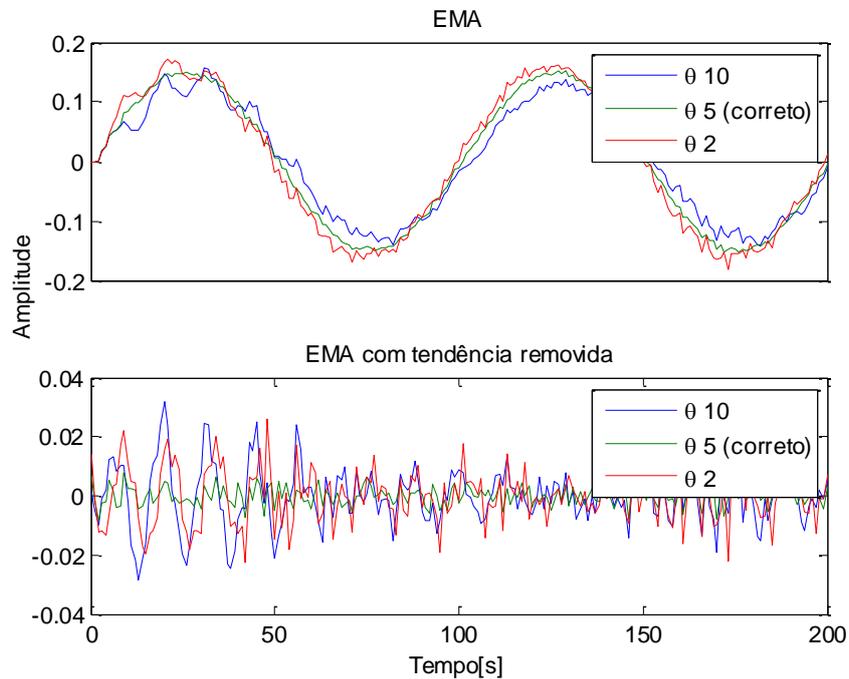


Figura 3.6: Comportamento do EMA e do EMA com tendência removida para modelos que diferem apenas no tempo morto.

Algumas alternativas para a remoção da tendência do sinal são detalhadas a seguir.

3.3.1 Uso da Derivada do Sinal

Uma forma conveniente de eliminar os efeitos do distúrbio não medido do sinal EMA é através da derivada do sinal (Tranter 2000). A derivada de um sinal pode ser aproximada numericamente pela diferença entre os elementos adjacentes:

$$Y = [X(2) - X(1) \quad X(3) - X(2) \quad \dots \quad X(m) - X(m - 1)] \quad (3.7)$$

Onde X é o vetor a ser derivado de tamanho m . Y a derivada aproximada de X .

Muito comum a necessidade de derivar o sinal mais de uma vez de forma a eliminar completamente a tendência não linear. Desta forma é necessário encontrar a ordem de derivação adequada. Ao fazer uso de derivações de sinais cabe salientar que há um limite no número de derivações sucessivas que podem ser empregadas de forma a manter a integridade das informações do sinal, já que imprecisões numéricas podem corrompê-las. Ainda, derivações sucessivas podem se tornar ineficazes devido à presença de excesso de

ruído de medição, sendo, portanto, necessário um pré-tratamento de dados adequado. Desta forma, o uso da derivação não é a melhor opção para a metodologia proposta.

3.3.2 Ajuste Polinomial

Alternativa para remover o efeito do distúrbio é fazer uso de um ajuste polinomial do sinal EMA.

Os coeficientes do ajuste polinomial são obtidos através do método dos mínimos quadrados, minimizando o erro entre o sinal *EMA* e o polinômio:

$$\min_{P_1 \dots P_{n+1}} (EMA - P)^2 \quad (3.8)$$

Onde:

$$P(t) = P_1 t^n + P_2 t^{n-1} + \dots + P_n t + P_{n+1} \quad (3.9)$$

Sendo n é a ordem do polinômio (parâmetro de suavização) ao longo do tempo t . Note que o parâmetro de suavização não está presente na função objetivo acima, ou seja, dado um determinado parâmetro de suavização determinam-se os coeficientes do polinômio.

O ajuste polinomial é subtraído do sinal do EMA e considera-se que o sinal resultante é decorrente do efeito do tempo morto, assumindo-se que a tendência foi removida pelo ajuste polinomial.

Um aspecto importante desta metodologia consiste na determinação da ordem n mais adequada do polinômio (parâmetro de suavização). Isto deve ser feito de forma a evitar superparametrizações (*overfitting*), uma vez que, se a ordem polinomial for demasiadamente elevada o ajuste é quase perfeito, o que inviabilizaria a etapa de otimização subsequente que busca estimar o tempo morto a partir do resíduo ($EMA - P$).

Para a obtenção de uma ordem adequada sugere-se uma heurística baseada no erro quadrático de ajuste $(EMAi - P)^2$, onde $EMAi$ é o sinal EMA inicial, obtido a partir do modelo inicial e de um tempo morto chute inicial que esteja contido dentro da faixa de busca.

Sendo assim, os coeficientes do ajuste polinomial da heurística são obtidos através do método dos mínimos quadrados, minimizando o erro entre o sinal $EMAi$ e o polinômio.

$$\min_{P_1 \dots P_n} (EMAi - P)^2 \quad (3.10)$$

Para a obtenção de uma ordem n sugere-se avaliar a curva de erro quadrático de ajuste $(EMAi - P)^2$ versus ordem do polinômio conforme ilustra a Figura 3.7. Por motivos de precisão numérica sugere-se o uso de ordens polinomiais abaixo de 20.

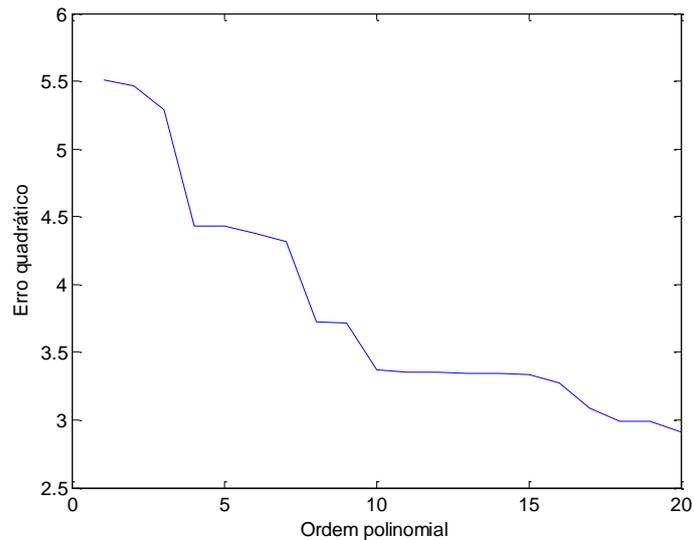


Figura 3.7: Curva de erro quadrático entre $EMAi$ e polinômio de ajuste versus ordem polinomial.

Observa-se que a partir de uma determinada ordem, o incremento do polinômio não altera de forma significativa o erro quadrático. Sendo assim, uma forma eficaz de encontrar a ordem adequada é através da soma cumulativa do erro quadrático.

Desta forma, sugere-se que a razão entre a soma cumulativa total e a soma cumulativa selecionada seja 0.85. Este valor é uma heurística obtida a partir de exaustivas avaliações da metodologia proposta. No caso acima a ordem escolhida foi 17, cujo resultado é ilustrado na Figura 3.8.

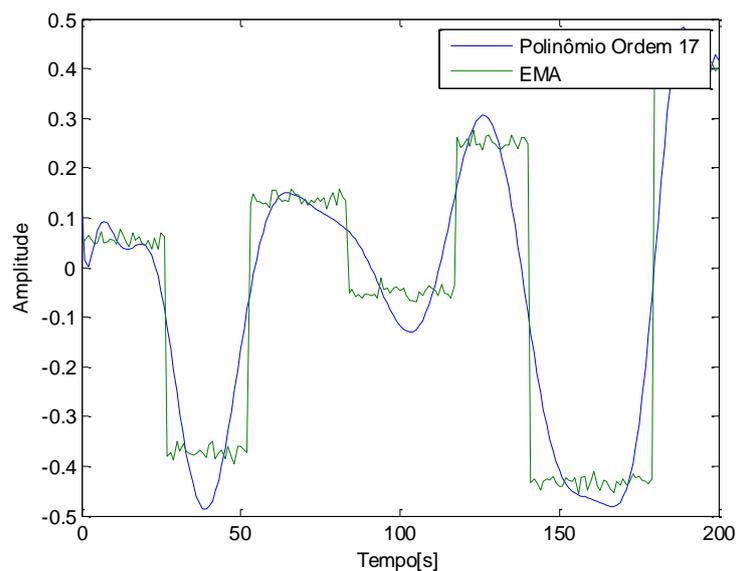


Figura 3.8: Comportamento do EMA e do respectivo polinômio de ordem 17.

3.3.3 Splines Suavizantes

Ainda, como alternativa para remoção do efeito do distúrbio, pode-se ser empregado o uso de *splines* suavizantes.

Da mesma forma que o ajuste polinomial, considerando um sinal EMA inicial EMA_i obtido a partir do modelo inicial e de um tempo morto chute inicial que esteja contido dentro da faixa de busca. A *spline* suavizante cúbica S é construída através da minimização da seguinte função objetivo:

$$p \sum_i w_i (EMA_i - S(t_i))^2 + (1 - p) \int \left(\frac{d^2 S}{dt^2} \right)^2 dx \quad (3.11)$$

Onde S é a *spline* suavizante, p o parâmetro de suavização e w_i são os pesos da *spline*. Sendo que w_i , quando não especificado é considerado como padrão 1 para todos os pontos i .

Da mesma forma que com polinômios, é necessário encontrar o parâmetro de ajuste (neste caso, parâmetro de suavização p da *spline*). Isto pode ser feito de forma similar a abordagem utilizada na aproximação polinomial, isto é, através de uma curva de erro quadrático $(EMA_i - S)^2$, onde o parâmetro de suavização referente a 0.85 do erro quadrático acumulado é selecionado, evitando superparametrizações, como na Figura 3.9. Na Figura 3.10 segue o comportamento do EMA e da respectiva *spline* com parâmetro de suavização 0.1.

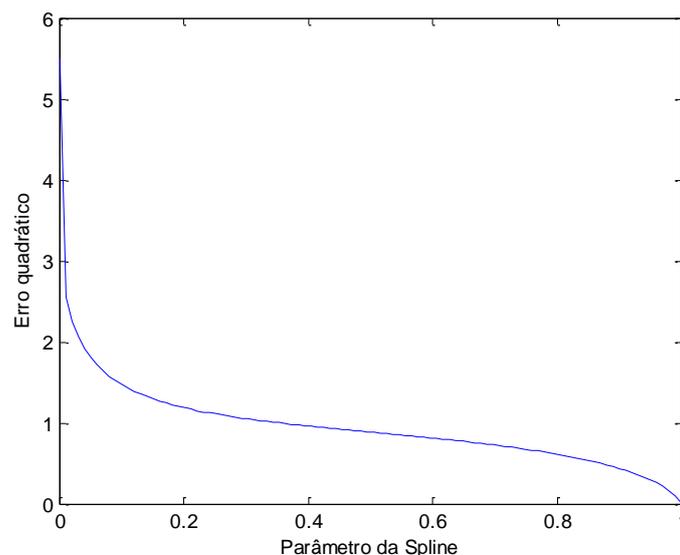


Figura 3.9: Curva de erro quadrático entre EMA e *spline* de ajuste versus parâmetro de suavização.

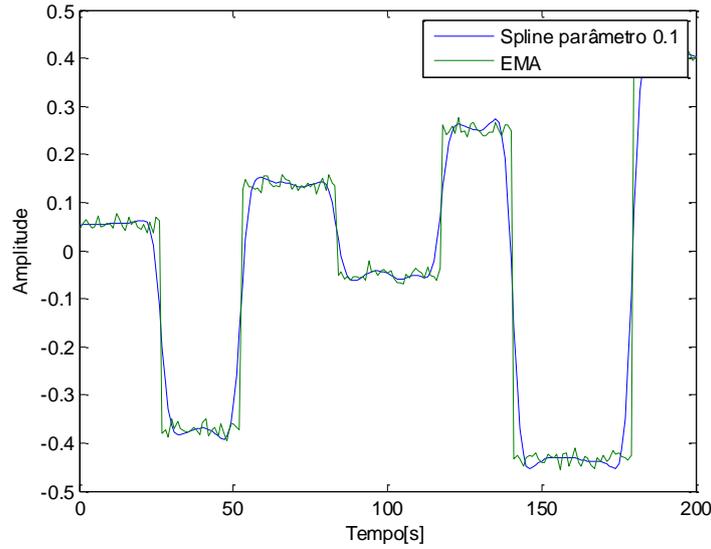


Figura 3.10: Comportamento do EMA e da respectiva *spline* com parâmetro de suavização 0.1.

3.4 Formulação da Função Objetivo

Neste trabalho duas abordagens são sugeridas para estimação do tempo morto, as quais serão discutidas a seguir:

3.4.1 Minimização da variância do resíduo do erro em malha aberta

O modelo inicial, conforme visto na seção 3.1, é necessário para obtenção do sinal EMA durante cada passo do processo de otimização. Durante o processo de estimação do tempo morto os outros parâmetros deste modelo são mantidos constantes durante a otimização, já que o objetivo é detectá-lo.

Após a remoção dos efeitos do distúrbio não medido do EMA (discutido na seção 3.2), os efeitos do parâmetro tempo morto estão mais evidentes. Sendo assim, considerando o sinal “isento” dos efeitos de distúrbios, a determinação do tempo morto esta centrada na eliminação do excesso de oscilações do sinal (pois conforme já discutido, o tempo morto é a principal causa deste efeito).

Considerando que as oscilações do sinal podem ser mensuradas através da variância do sinal avaliado, define-se a seguinte função objetivo que busca minimizar a variância do sinal do erro em malha aberta com tendência removida (EMA_{mod}), também denominado resíduo do erro em malha aberta:

$$\min_{\theta} (\text{var}(EMA_{mod})) \quad (3.12)$$

Onde θ é o tempo morto, var representa a variância, $EMA_{mod} = EMA - S$ quando a remoção do distúrbio é realizada através da *spline* suavizante, ou $EMA_{mod} = EMA - P$, quando realizada através de ajuste polinomial.

Este problema de otimização é não convexo e, portanto, pode apresentar mínimos locais. Sendo assim, é necessário o uso de um algoritmo de otimização capaz de encontrar o mínimo global. Para este trabalho utilizou-se o PSO (*particle swarm optimization*). Cabe salientar, que após se determinar o parâmetro de suavização para remover o efeito do distúrbio não medido a única variável de decisão do problema 3.10 é o tempo morto. Por ser um problema de otimização monovariável diversas alternativas poderão ser empregadas (ACO - *Ant Colony Optimization*, GA - *Genetic Algorithm*), ou a análise gráfica da curva θ vs função objetivo.

A única restrição utilizada neste problema de otimização são os limites inferiores e superiores de busca do parâmetro tempo morto. Esses valores devem ser representativos com a dinâmica do sistema em estudo e podem ser obtidos com base no padrão de comportamento da referida planta ao longo de um tempo de operação.

Na Figura 3.11 é mostrado o gráfico da função objetivo para o exemplo fazendo uso da derivada primeira do EMA. Nota-se a presença de um mínimo global saliente próximo ao tempo morto verdadeiro do sistema, que é igual a cinco segundos, conforme a equação 3.3.

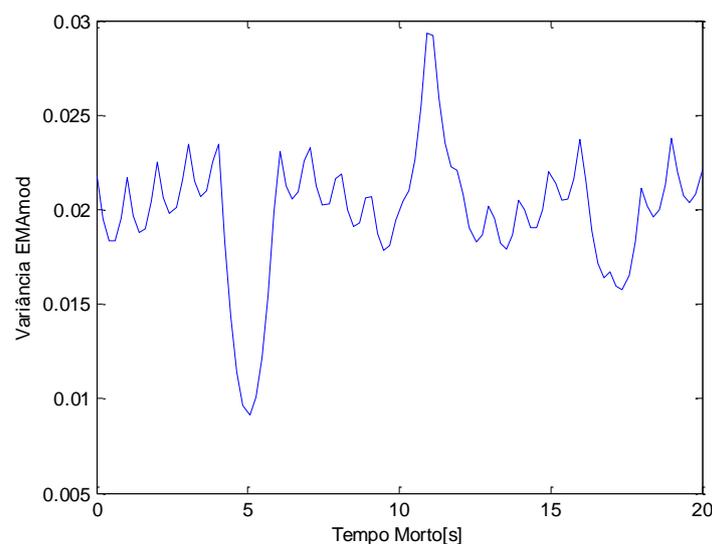


Figura 3.11: Função objetivo fazendo uso de derivação para remover tendência não linear.

Na Figura 3.12 é mostrado o gráfico da função objetivo para o exemplo fazendo uso do polinômio de ordem 17 para remover a tendência do EMA. Novamente é perceptível a presença de um mínimo global próximo ao tempo morto verdadeiro. Na Figura 3.13 é possível visualizar a curva da função objetivo versus o parâmetro de suavização polinomial e o tempo morto. A ordem do parâmetro de suavização, neste caso ordem polinomial, deve ser acima de dois, pois o objetivo é remover a tendência não linear.

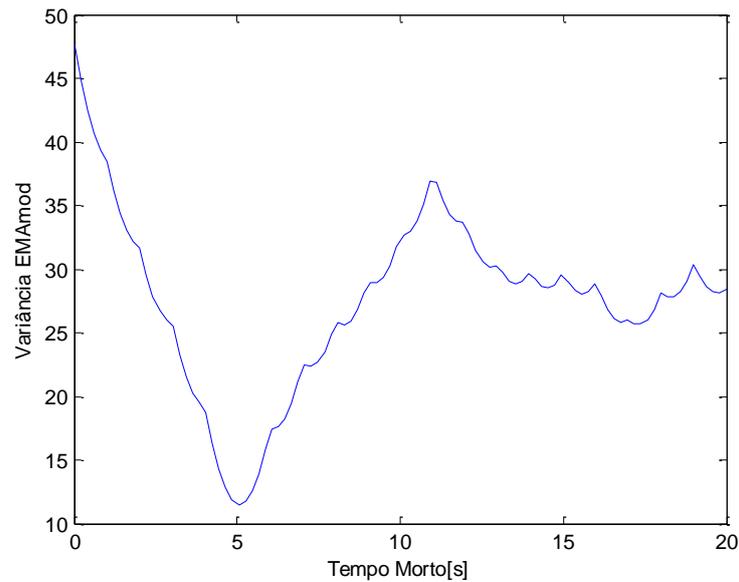


Figura 3.12: Função objetivo fazendo uso de ajuste polinomial para remover tendência não linear.

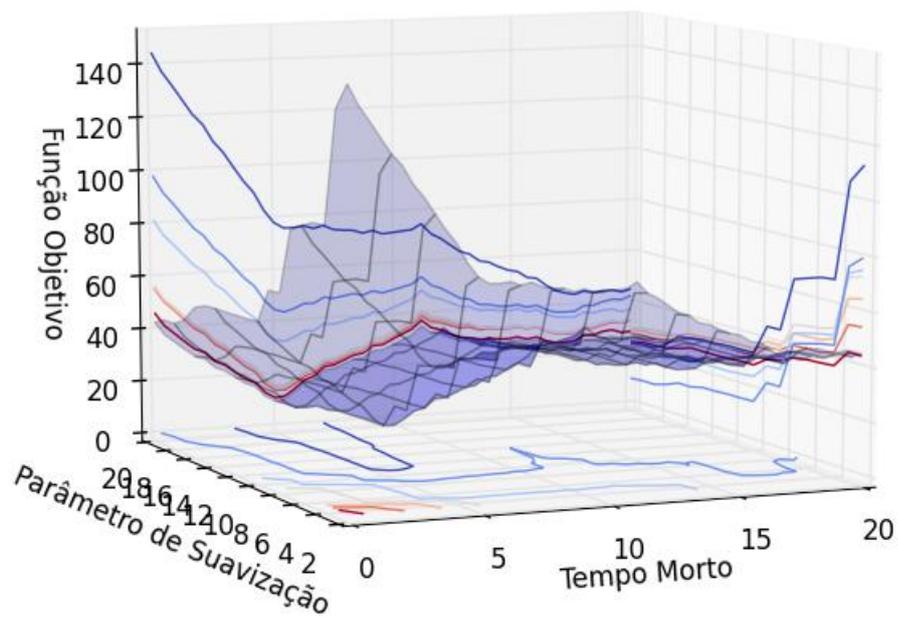


Figura 3.13: Função objetivo versus o parâmetro de suavização polinomial e o tempo morto.

A escolha do parâmetro de suavização é uma etapa crítica na metodologia, pois influencia diretamente no resultado. A heurística apresentada é uma forma que, na maioria das vezes, traz bons resultados, mas não garante sucesso. Em situações que o parâmetro de suavização não foi escolhido de forma adequada (por exemplo, polinômio de ordem 3), o comportamento da função objetivo será semelhante ao da Figura 3.14.

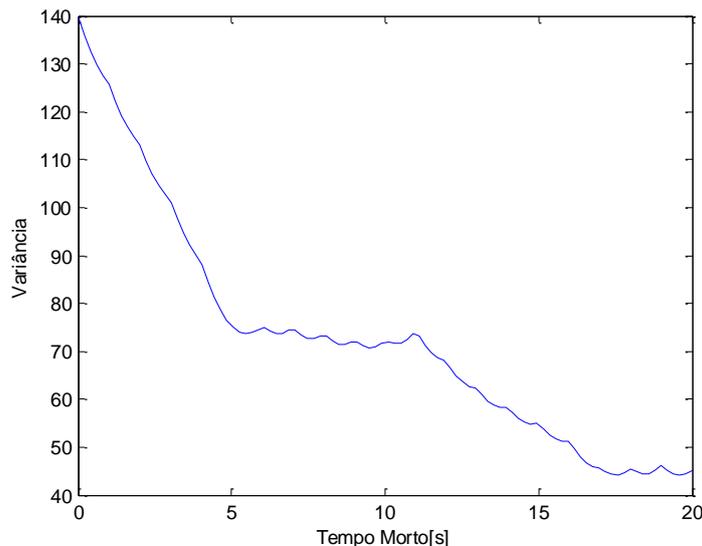


Figura 3.14: Comportamento típico da função objetivo quando o parâmetro de suavização escolhido não foi adequado.

Ainda, cabe ressaltar que não poderia ser utilizado o mínimo global da Figura 3.13, pois ele seria referente a uma superparametrização do sinal do EMA e, na maioria das vezes, representaria um resultado equivocado (embora na Figura 3.13 uma otimização de dois parâmetros teria sido bem sucedida, isso nem sempre irá ocorrer). A superparametrização do EMA torna o resíduo (sinal obtido após removida a tendência) praticamente ruído numérico, de forma que a função objetivo de variância não tenha sensibilidade de mensurar.

Na Figura 3.15 pode-se visualizar o gráfico da função objetivo para o exemplo da seção anterior fazendo uso de *splines* suavizantes com suavização 0.1 para remover a tendência do EMA. Como esperado o mínimo global está próximo do tempo morto verdadeiro do sistema. Na Figura 3.16 é possível visualizar o comportamento da função objetivo versus o parâmetro de suavização *spline* e o tempo morto. Nota-se que as *splines* suavizantes utilizadas neste trabalho possuem um parâmetro de suavização que varia de 0 até 1, onde o parâmetro 0 significa a utilização de um ajuste linear e o parâmetro 1 produz uma *spline* cúbica interpolante, portanto não devem ser incluídos na região de busca da função objetivo. *Splines* suavizantes tendem a ter grande sensibilidade na parametrização do sinal, desta forma é indicado definir a região de busca do parâmetro de suavização da *spline* de 0.00001 até 0.1.

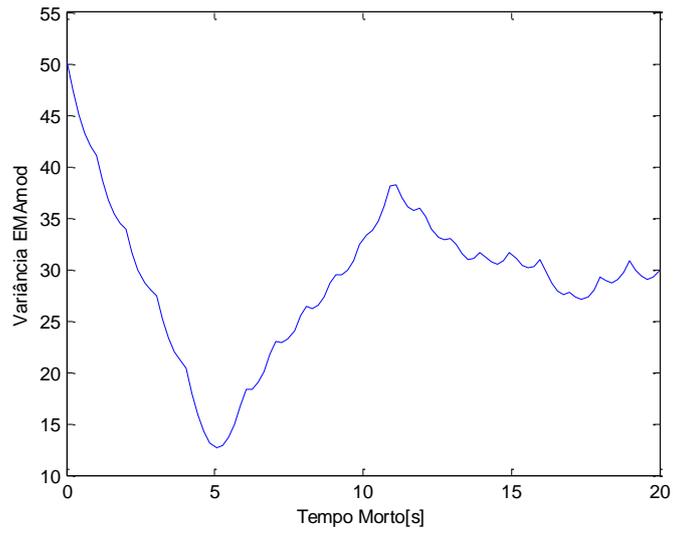


Figura 3.15: Função objetivo de variância fazendo uso de *spline* para remover tendência não linear.

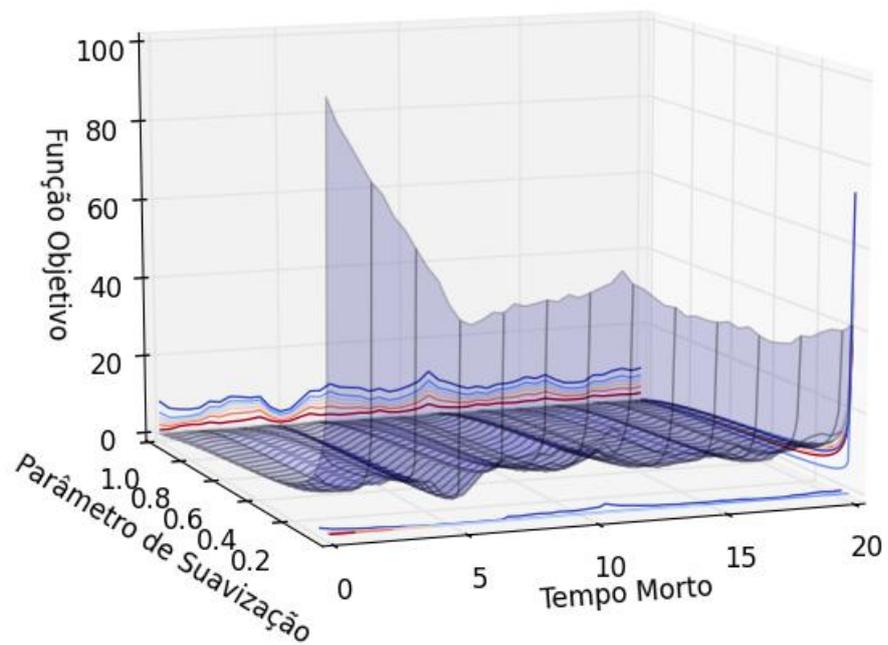


Figura 3.16: Função objetivo de variância versus o parâmetro de suavização de *spline* e o tempo morto.

3.4.2 Minimização dos desvios do resíduo do erro em malha aberta

Uma alternativa para minimização das oscilações do EMA_{mod} , provenientes do tempo morto incorreto, além daquela proposta na seção 3.4.1, consiste em minimizar os desvios do resíduo do erro em malha aberta em torno de sua tendência. Para deixar mais claro considere o caso em estudo como exemplo. Ao definir o parâmetro de suavização da *spline* para 0.7, com modelos que diferem apenas no tempo morto (TD), o gráfico da distribuição de probabilidade normal do resíduo do EMA pode ser visualizado na Figura 3.17.

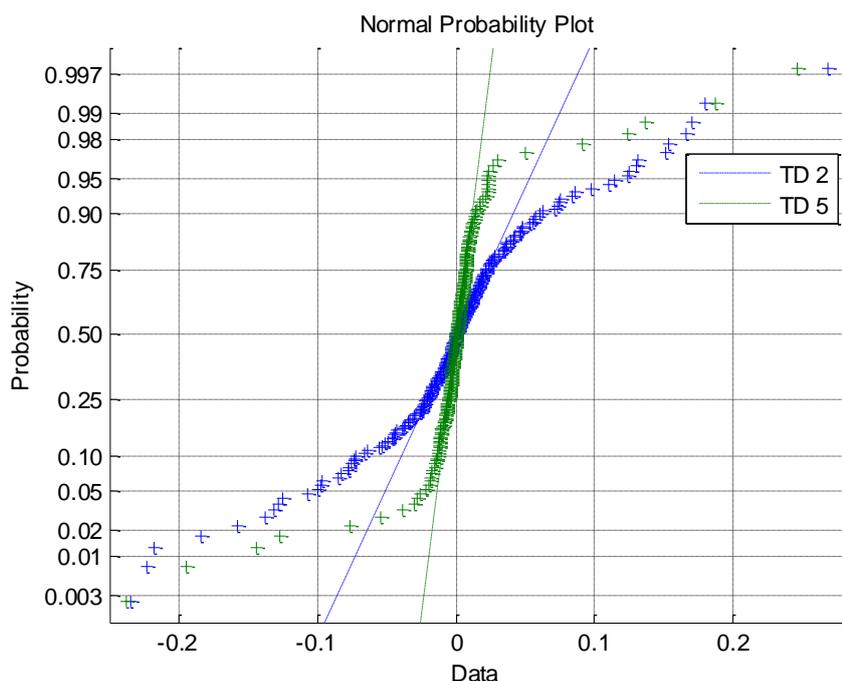


Figura 3.17: Distribuição de probabilidade normal do resíduo do EMA.

Um aspecto a ser observado é que estas curvas de distribuição do resíduo tendem a ter formato sigmoidal. Além disso, pode se observar que a distribuição de probabilidade do modelo com tempo morto correto (5) possui uma maior quantidade de pontos em cima da reta de distribuição normal (pontilhada). A ideia proposta é minimizar o espalhamento dos dados frente a esta reta normal. Uma sugestão para quantificar este espalhamento é através de um ajuste linear com os dados da distribuição (linha contínua), que pode ser visualizado na Figura 3.18.

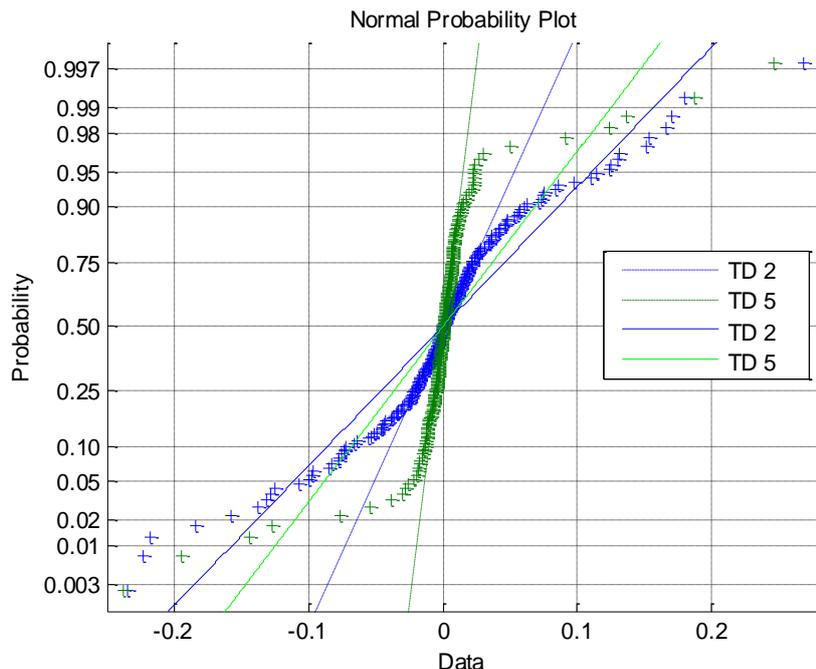


Figura 3.18: Distribuição de probabilidade normal do resíduo do EMA e retas da regressão linear.

Tomando o ajuste linear destes pontos e calculando o coeficiente de determinação das retas contínuas, fica evidente a diferença entre o tempo morto correto e o incorreto, uma vez que o R^2 para o modelo com tempo morto de 2 foi 0.9037 e o R^2 para o modelo com tempo morto de 5 (correto) foi 0.5226. Isso significa que o modelo com tempo morto correto tende a ser mais “suave”, ou seja, com menor número de desvios em relação a sua tendência.

Desta forma é possível definir a função objetivo que minimiza o coeficiente de determinação (R^2) da regressão linear da curva de distribuição de probabilidade dos dados (resíduo do *EMA*):

$$\min_{\theta} (R^2(EMAm_{od})) \quad (3.13)$$

Ambas as abordagens de função objetivo são semelhantes por natureza e dependem fortemente do parâmetro de suavização. Contudo, a função objetivo proposta nesta seção possui uma particularidade frente aquela proposta na subseção anterior. O seu comportamento tende a facilitar a estimação do tempo morto, uma vez que favorece a formação de mínimos globais, diferentemente da anterior, que adquiria a formação de platô e, portanto, dependia de uma heurística para obter o parâmetro de suavização.

O formato da função objetivo de variância é desfavorável pela superparametrização do *EMA* com valores altos de parâmetro de suavização. Isto acontece porque, com a superparametrização do *EMA*, o seu resíduo se torna praticamente nulo (nível de ruído) e a variância deste ruído reduz drasticamente. A função objetivo de coeficiente de determinação ocorre o contrário, isto é, o valor da função objetivo sobe drasticamente quando o parâmetro de suavização é alto (superparametrização), justamente pelo fato de

que o ruído de medição (resíduo do EMA) é um sinal gaussiano/normal. Sendo assim, vale destacar que esta função objetivo tende a obter melhores resultados com ordens de suavização pequenas.

Sendo assim, nas Figura 3.19 e Figura 3.20 é possível visualizar os gráficos da função objetivo de coeficiente de determinação para o exemplo em discussão.

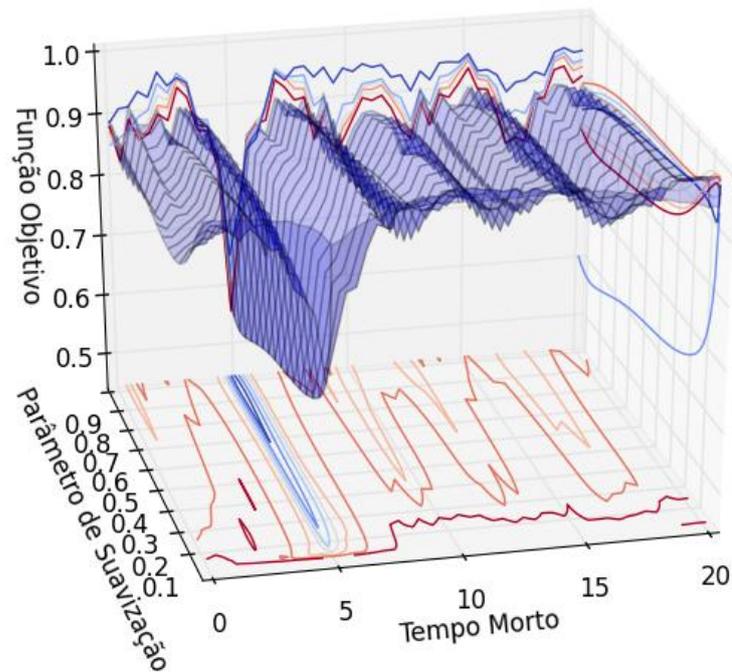


Figura 3.19: Função objetivo versus o parâmetro de suavização de *spline* e o tempo morto.

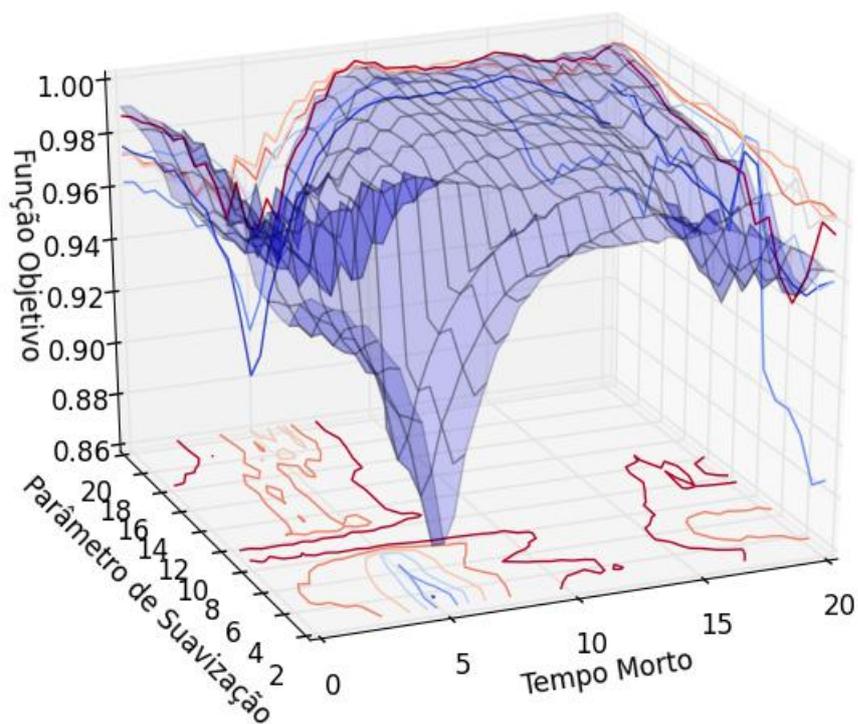


Figura 3.20: Função objetivo versus o parâmetro de suavização polinomial e o tempo morto.

Um importante aspecto a se destacar sobre o uso de polinômios como suavização é que o uso de ordens polinomiais baixas (menores que quatro) pode gerar “efeito de borda” na suavização da janela de dados ocasionando erros na estimação. Desta forma, com a função objetivo de coeficiente de determinação é aconselhado fazer uso de *splines* suavizantes. Na Figura 3.21 pode ser visualizado o comportamento da função objetivo considerando o parâmetro de suavização como 0.7 e na Figura 3.22 a distribuição de probabilidade normal para os diferentes tempos mortos com suavização 0.7.

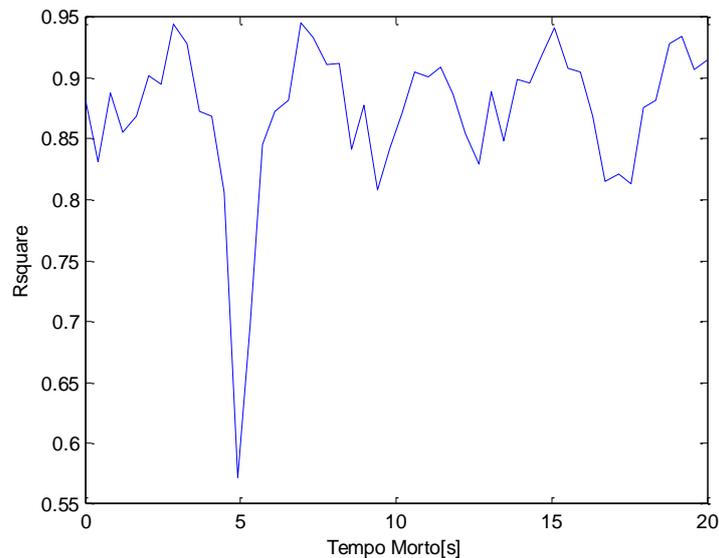


Figura 3.21: Função objetivo fazendo uso de *spline* para remover tendência não linear.

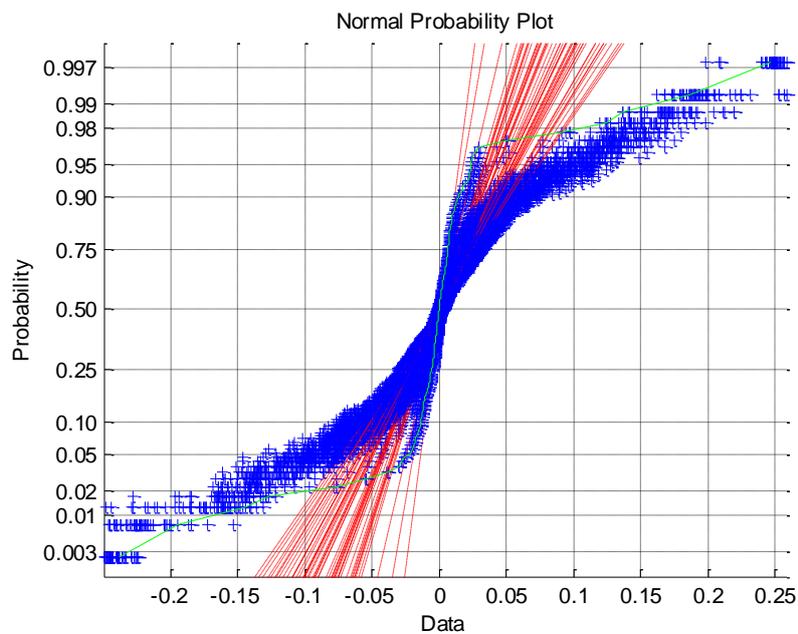


Figura 3.22: Distribuição de probabilidade normal para parâmetro de suavização 0.7 e diferentes tempos mortos onde a curva verde representa o tempo morto correto.

3.5 Otimização do Modelo Inicial

É natural que um método de estimação de parâmetros possua dependência do modelo inicial na estimação. Nas técnicas tradicionais de estimação, quanto mais próximo do comportamento real o modelo, melhores as chances de se obter uma estimação correta.

A metodologia proposta por este trabalho também possui certa dependência do modelo. Contudo, a relação de dependência neste caso difere em certo aspecto. Isto porque ela não é necessariamente favorecida por um modelo mais próximo do comportamento real do processo, mas sim por um modelo que favoreça a sensibilidade da função objetivo ao tempo morto, considerando que a análise dos sinais gerados se dá de forma relativa a este parâmetro.

Dessa forma, verifica-se que é possível aumentar a eficiência da estimação com breves alterações no modelo de forma a aumentar a sensibilidade da função objetivo.

Isso pode ser feito com uma simples alteração do ganho proporcional do modelo inicial visando reduzir a razão sinal ruído, que por sua vez é definida como:

$$\frac{\text{var}(EMA)}{\text{var}(EMA_{mod})} \quad (3.14)$$

Uma redução na razão sinal ruído implica tornar os sinais mais sensíveis a variações no parâmetro tempo morto e com isso aumentar a sensibilidade da função objetivo. Nos estudos de caso adiante serão mostradas situações onde estas alterações foram capazes de melhorar o formato da curva da função objetivo. Desta forma é possível propor uma otimização que visa ajustar o ganho e a constante de tempo do modelo para obter resultados mais eficazes.

Na Figura 3.23 é possível visualizar um comportamento típico do EMA quando o modelo não favorece a influência do tempo morto no sinal, levando a falta de sensibilidade na função objetivo, como na Figura 3.24. Para estes casos seria possível alterar o modelo de forma a favorecer o surgimento de mínimos locais na função objetivo.

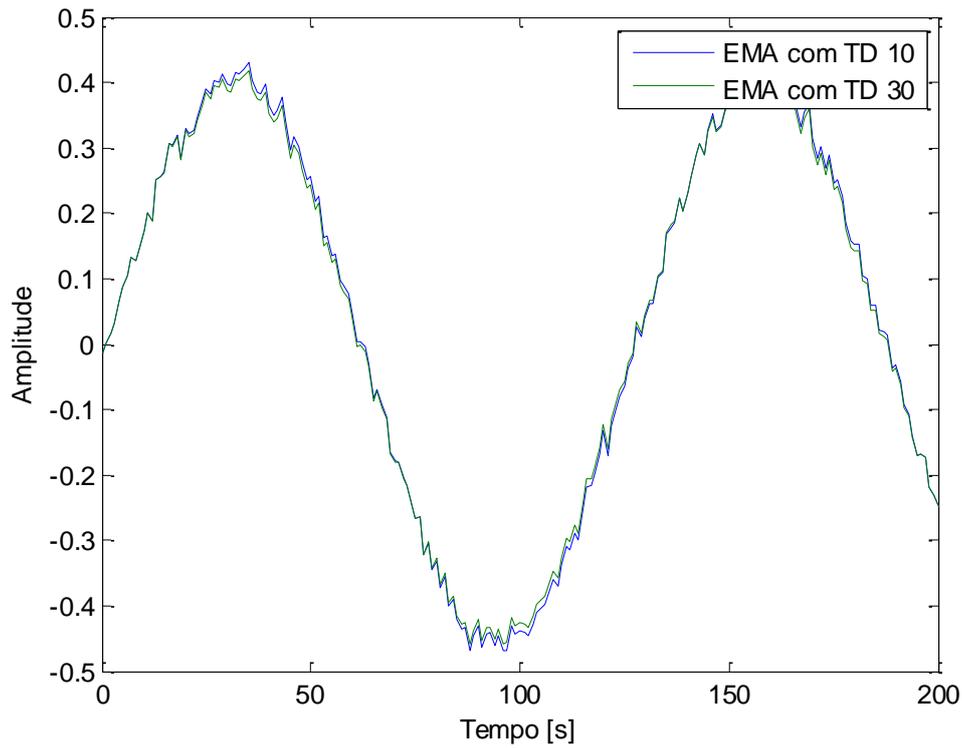


Figura 3.23: Comportamento típico do EMA para um modelo desfavorável à estimação.

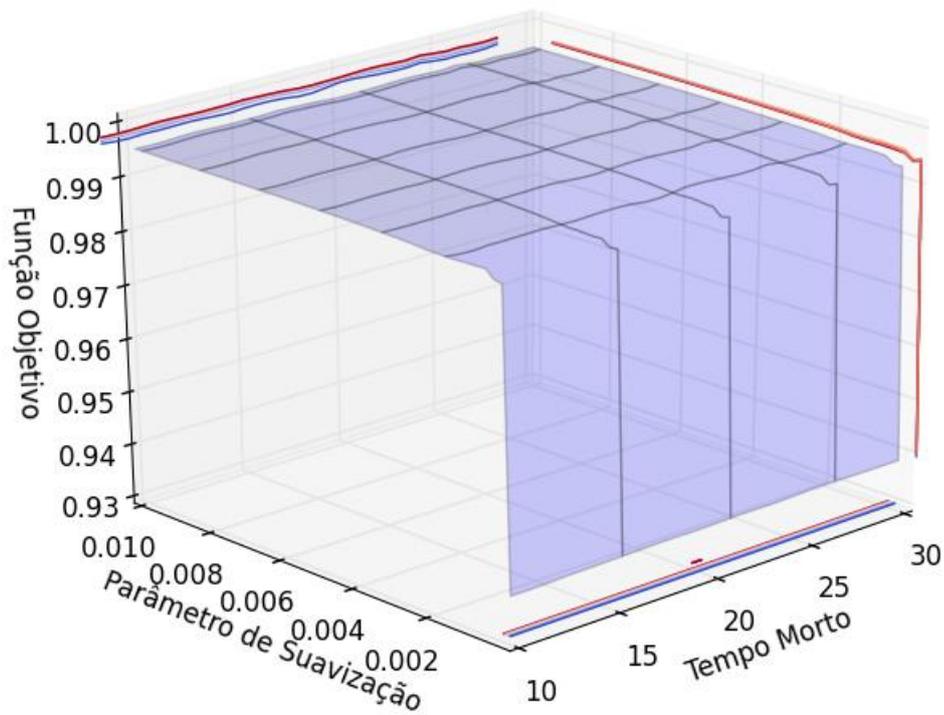


Figura 3.24: Comportamento típico da função objetivo versus o parâmetro de suavização e o tempo morto quando o modelo é desfavorável à estimação.

3.6 Definição do Tamanho da Janela de Dados

O coeficiente de determinação, como ferramenta estatística, é muito utilizado para avaliar qualidade de modelos lineares. O coeficiente indica o quanto o modelo foi capaz de explicar os dados coletados (diferente deste trabalho faz uso do coeficiente para quantificar os desvios dos dados em torno da sua tendência).

A utilização do coeficiente de determinação, de modo geral, implica em uma série de precauções (Montgomery et al. n.d.):

1. O R^2 deve ser usado com precaução, pois é sempre possível torná-lo maior pela adição de um número suficiente de termos ao modelo. Assim, se, por exemplo, não há dados repetidos (mais do que um valor y para um mesmo x) um polinômio de grau $(n - 1)$ dará um ajuste perfeito R^2 para n dados. Quando há valores repetidos, o R^2 não será nunca igual a 1, pois o modelo não poderá explicar a variabilidade devido ao erro puro. Um grande número de parâmetros, mesmo que tenha muito pouco poder explicativo sobre a variável dependente, resulta em um aumento indiscriminado no valor de R^2 , se caracterizando em um equívoco estatístico. De modo geral isto incentiva a inclusão indiscriminada de variáveis em ajustes lineares, prejudicando o princípio da parcimônia (Navalha de Occam).
2. Embora R^2 aumente com a adição de termos ao modelo, isto não significa necessariamente que o novo modelo é superior ao anterior. Na realidade esse novo modelo poderá ser pior.
3. Em geral, também, R^2 não mede a magnitude da inclinação da reta. Um valor grande de R^2 não significa uma reta mais inclinada. Além do mais, ele não leva em consideração a falta de ajuste do modelo; ele poderá ser grande, mesmo que y e x estejam não linearmente relacionados. Dessa forma, vê-se que R^2 não deve ser considerado sozinho, mas sempre aliado a outros diagnósticos do modelo.
4. A magnitude de R^2 , também, depende da amplitude de variação da variável regressora x . Geralmente, R^2 aumentará com maior amplitude de variação dos x 's e diminuirá em caso contrário. Pode-se mostrar pelo método delta (Hahn 1972) que:

$$E(R^2) \cong \frac{\hat{\alpha}^2 \sum_{i=1}^n (x_i - \bar{x})^2}{\hat{\alpha}^2 \sum_{i=1}^n (x_i - \bar{x})^2 + \sigma^2} \quad (3.15)$$

Onde $E(R^2)$ é a estimativa do coeficiente de determinação, x a variável regressora (independente) com n observações (tamanho da janela de dados) e média \bar{x} , α o parâmetro do modelo linear estimado e σ^2 a variância da população.

Assim, um valor grande de R^2 poderá ser grande simplesmente porque x variou em uma amplitude muito grande, representada pelo termo $\sum_{i=1}^n (x_i - \bar{x})^2$. Por outro lado R^2 poderá ser pequeno porque a amplitude dos x 's foi muito pequena para permitir que uma relação com y fosse detectada.

Dentre as precauções listadas, a mais relevante para a metodologia proposta por este trabalho é a número 4. Ela basicamente sugere que o coeficiente de determinação

depende fortemente do tamanho da janela de dados utilizada para aplicar a metodologia (n). Verifica-se um decréscimo na sensibilidade da função objetivo quando as janelas de dados são muito grandes, similar ao comportamento da Figura 3.24. Isso ocorre, pois o coeficiente de determinação aumentou indiscriminadamente pelo grande número de observações. Desta forma o mais conveniente é fazer uso de janelas de dados pequenas. Sendo assim, propõe-se fragmentar o conjunto de dados em janelas menores e aplicar a metodologia em cada fragmento, no formato de janelas móveis.

Uma proposta conveniente de determinar o tamanho da janela de dados seria através da frequência que o tempo morto afeta o *EMA*, uma vez que a determinação do parâmetro é justamente através deste efeito. Isto pode ser feito ao se analisar o espectro de amplitude do EMA (*Single Sided Amplitude Spectrum*) para tempo mortos distintos, dentro da faixa de busca estipulada (por exemplo, os limites de busca do tempo morto). O que se observa é uma diferença significativa entre os dois espectros, refletindo em quais frequências o tempo morto interfere no sistema.

O gráfico resultante da diferença dos dois *Single Sided Amplitude Spectrum* pode ser obtido para facilitar a visualização. É muito comum a existência de um valor mínimo/máximo indicando que o parâmetro afeta fortemente aquela determinada frequência. Este valor de frequência pode ser então simplificaradamente convertido em um intervalo de tempo através da seguinte relação:

$$T = 1/F \quad (3.16)$$

Onde F é a frequência e T é o período em unidades internacionais.

O valor obtido reflete aproximadamente um intervalo de tempo que pode ser aproximado por um tamanho de janela suficientemente grande para estimação do parâmetro. De modo geral este valor pode ser arredondado para mais a fim de garantir quantidade suficiente de dados naquela janela.

A Figura 3.25 mostra o *Single Sided Amplitude Spectrum* do EMA para o exemplo estudado para diferentes tempos mortos (TD) considerando que não há erro de modelo no ganho e constante de tempo. A Figura 3.26 mostra a diferença entre estes espectros. O valor máximo corresponde à frequência de 0.0150Hz e a um período de 67s. Desta forma um tamanho de janela adequado seria em torno de 200 ou 100 segundos.

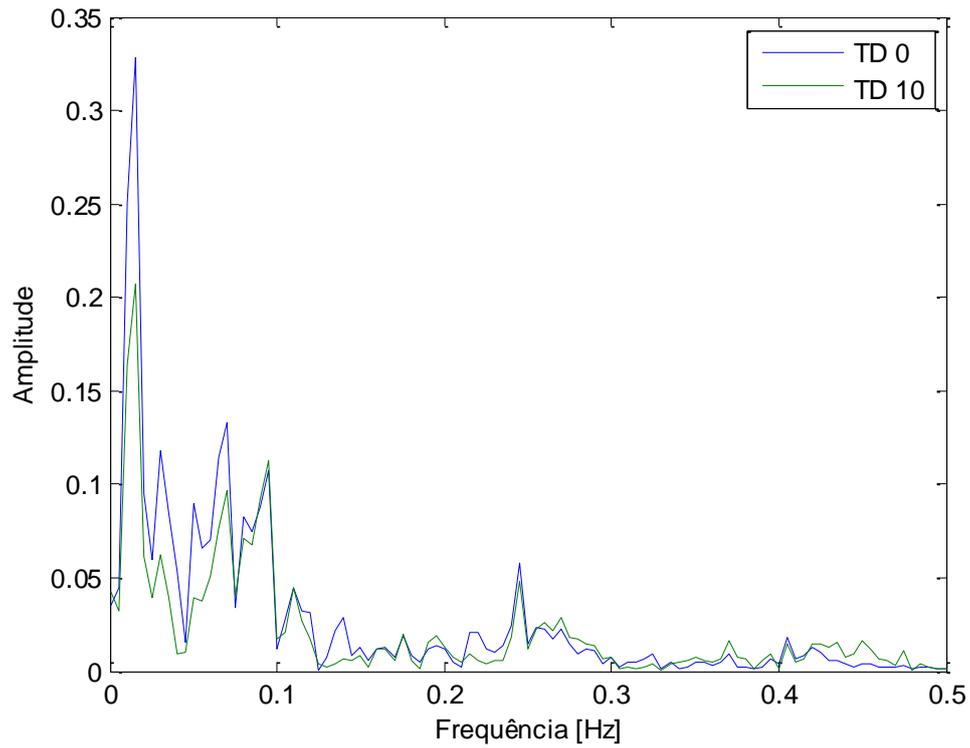


Figura 3.25: *Single Sided Amplitude Spectrum* do EMA para diferentes tempos mortos.

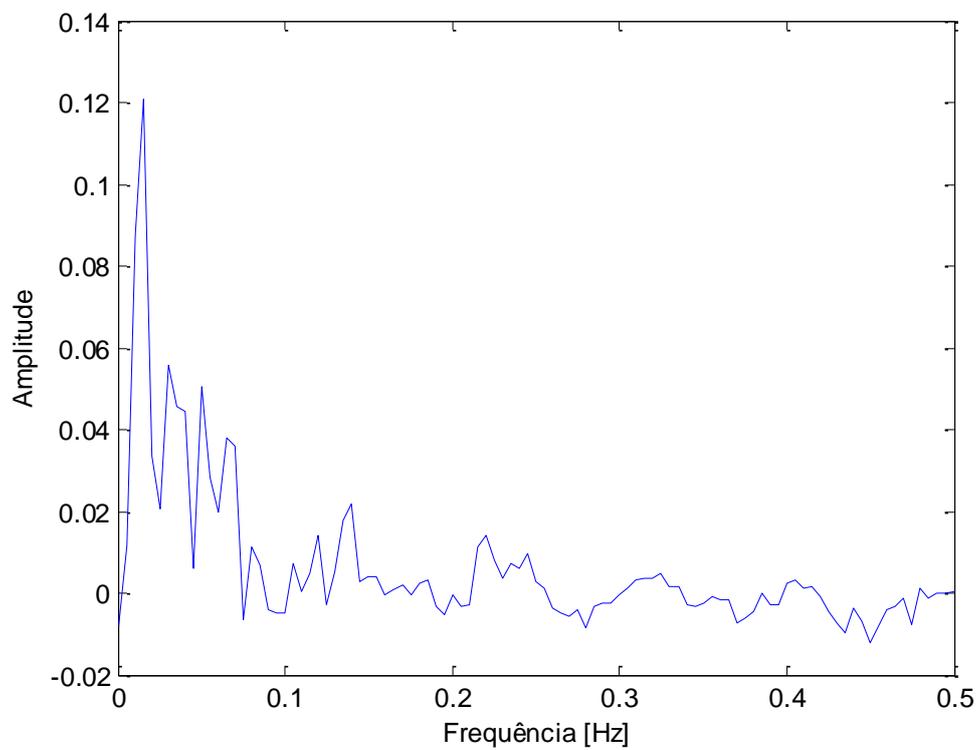


Figura 3.26: Diferença entre os *Single Sided Amplitude Spectrum*.

3.7 Fluxograma Esquemático

Nas seções anteriores as principais etapas necessárias para a estimação do tempo morto segundo a metodologia proposta foram apresentadas. Nesta seção, será discutido o procedimento de estimação, o qual integra todas estas etapas, conforme ilustra a Figura 3.27.

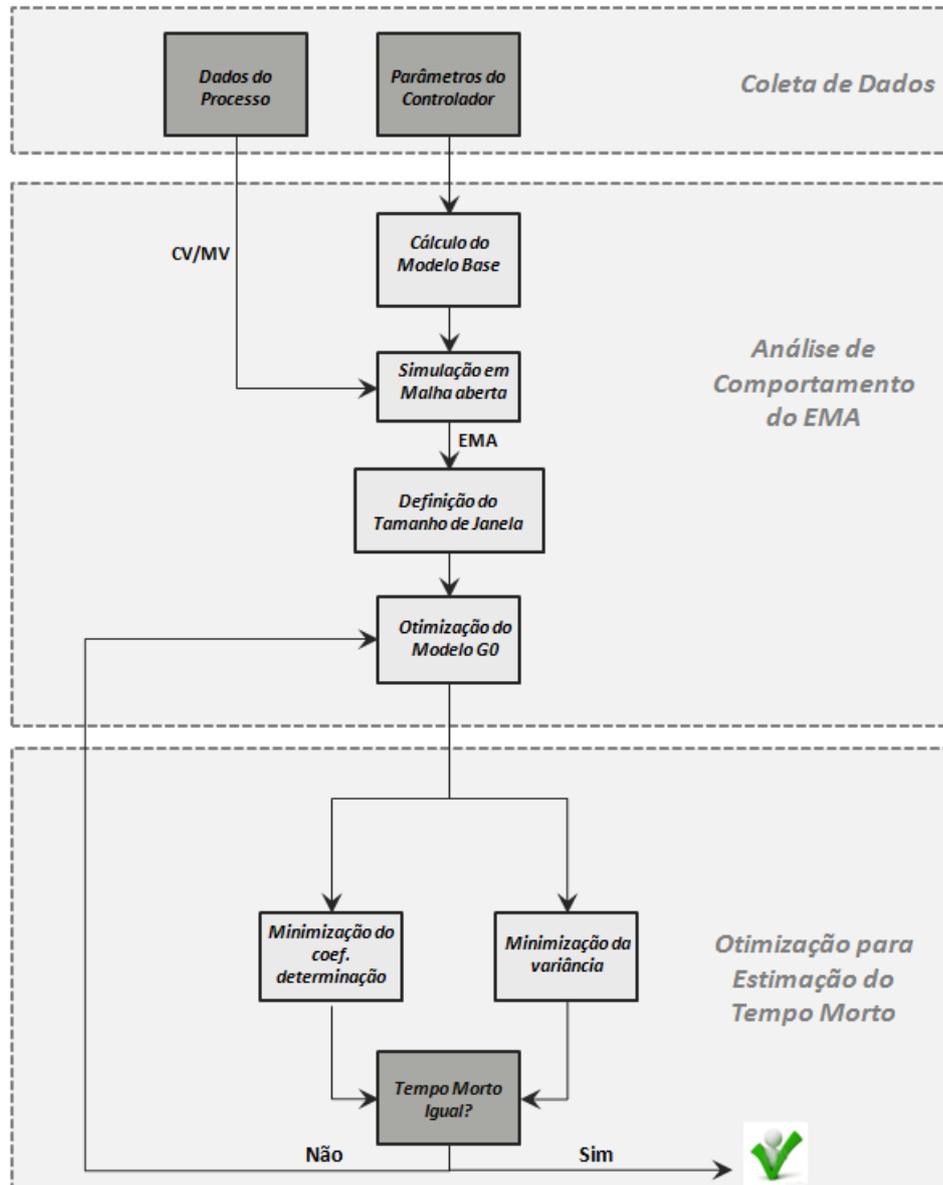


Figura 3.27: Fluxograma esquemático da metodologia proposta.

Conforme ilustrado na Figura 3.27, o procedimento parte dos parâmetros de sintonia do controlador e da coleta de dados históricos de processo. É importante ressaltar que os dados necessários são apenas as medições das variáveis controladas e manipuladas, sendo esta uma das principais vantagens da técnica proposta, visto que a mesma independe de dados com perturbações no *setpoint*.

A etapa seguinte consiste na obtenção do modelo base/inicial a partir dos parâmetros de sintonia do controlador. Em seguida é feita uma análise do comportamento do erro em malha aberta a fim de definir o tamanho da janela de dados adequada. Para isso são escolhidos dois tempo mortos, dentro da faixa de busca, para obtenção da diferença entre os espectros de amplitude, como descrito na seção 3.6. Em posse do tamanho da janela seria possível buscar uma alteração no modelo base de forma a facilitar a estimação do tempo morto pela influência do parâmetro no sinal do *EMA*. Etapa que futuramente pode ser implementada.

A etapa de otimização para estimação do tempo morto acontece com os parâmetros do modelo fixos, excetuando-se o tempo morto. A remoção da tendência do sinal *EMA* ocorre durante o processo de otimização.

No caso da função objetivo de variância, partindo de um *EMA* inicial (com tempo morto inicial dentro da faixa de busca) aplica-se a heurística para obtenção do parâmetro de suavização. Em posse deste parâmetro, é executado o algoritmo de otimização, que define um tempo morto, calcula o *EMA* e a *spline*/polinômio suavizante, em seguida subtrai os dois sinais para obtenção do EMA_{mod} e avalia a função objetivo a cada passo, sucessivamente até obter o mínimo global.

No caso da função objetivo de coeficiente de determinação não é necessário aplicar nenhuma heurística para obtenção do parâmetro de suavização, uma vez que o parâmetro de suavização é incluído dentro da função objetivo. A remoção da tendência do sinal *EMA* ocorre durante o processo de otimização, isto é, em cada passo da otimização o algoritmo de otimização define um tempo morto e um parâmetro de suavização. O algoritmo calcula o *EMA* e a *spline* suavizante, em seguida subtrai os dois sinais para obtenção do EMA_{mod} e avalia a função objetivo de coeficiente de determinação, sucessivamente até obter o mínimo global.

O fluxograma da Figura 3.27 sugere que possivelmente as duas funções objetivo podem ser aplicadas e que o parâmetro de suavização da função objetivo de variância pode ser obtido diretamente da função objetivo de coeficiente de determinação. Uma proposta futura seria implementar o algoritmo de forma que ambos os resultados das funções objetivo devem coincidir, caso contrário uma otimização do modelo base inicial seria necessária.

Capítulo 4 – Estudo de Casos - Simulados

Os processos industriais apresentam determinadas particularidades que limitam o desempenho do controlador como polos instáveis, zeros no semi-plano direito, distúrbios não medidos e tempo morto. Muitos das quais podem levar a instabilidade do sistema. Mesmo em sistemas operando dentro da faixa de estabilidade, a dinâmica da planta ou até mesmo o ajuste do controlador pode levar a um desempenho insatisfatório. Dentro de um grande conjunto de possibilidades, nesta seção objetivou-se selecionar um pequeno conjunto de estudos simulados capazes de representar os comportamentos tipicamente encontrados em sistemas reais.

A ideia deste capítulo é propor cenários que simulam tais características sob o efeito de diferentes distúrbios com objetivo de testar a qualidade da metodologia proposta para estimar o tempo morto. Os dados de simulação foram gerados através do *software Matlab*, assim como as rotinas de execução (*scripts*) da metodologia proposta.

4.1 Planta de Primeira Ordem – Tempo Morto Variável

Com o objetivo de avaliar a metodologia proposta para fins de monitoramento de malhas de controle o presente estudo de caso simula situações em que o tempo morto do sistema possa ser alterado em virtude de distúrbios ou alteração da dinâmica do processo. A planta é representada pela função de transferência abaixo:

$$\frac{1e^{-\theta s}}{10s+1} \quad (4.1)$$

A simulação tem ao todo 6000 segundos com tempo de amostragem 1. O tempo morto inicial era de 1.5 segundos e a alteração no tempo morto de sistema ocorreu no tempo de 3000 segundos para o valor de 3 segundos.

O controlador utilizado foi um PID com ganho proporcional de 0.3891, constante de tempo integral de 6.31 e constante de tempo derivativa de 0.093.

O ruído de medição é um sinal randômico branco com intensidade estipulada através do índice SNR (Wang & Zhang 2001), definido por:

$$SNR = \frac{\text{mean}(\text{abs}(\text{noise}))}{\text{mean}(\text{abs}(y))} \quad (4.2)$$

Onde *mean* é a média do sinal, *abs* o absoluto do sinal e *noise* o ruído de medição. Para este estudo de caso a intensidade do ruído de medição é SNR 15%.

O sinal que representa o distúrbio não medido pode ser visualizado na Figura 4.1, ele foi criado a partir de um ruído branco que foi colorido através de uma função de transferência de primeira ordem com ganho 3 e constante de tempo 550. A Figura 4.2 mostra a variável manipulada e a variável controlada para o estudo de caso 4.1.

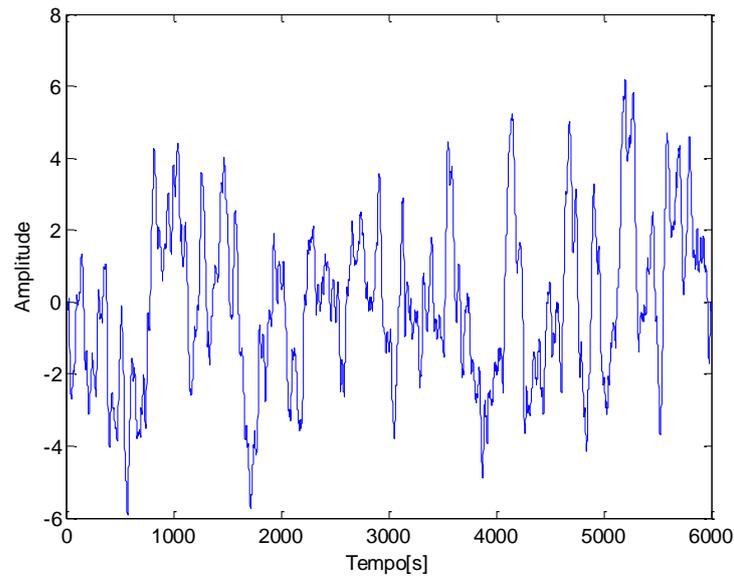


Figura 4.1: Sinal que representa o distúrbio não medido.

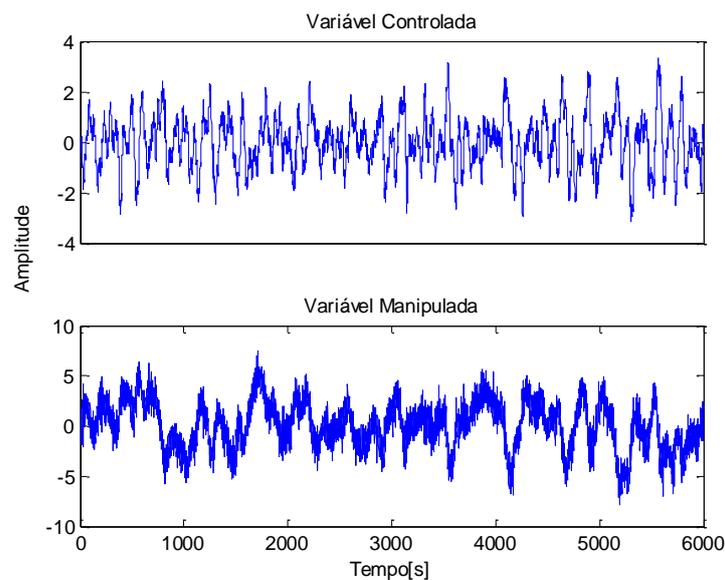


Figura 4.2: Variável controlada e variável manipulada.

Neste estudo de caso a metodologia, como descrita no fluxograma da Figura 3.27, foi aplicada em uma janela de dados antes da mudança do tempo morto e outra vez em outra janela de dados após a mudança do tempo morto, a fim de verificar a capacidade de capturar de forma correta a mudança do parâmetro.

O modelo base, calculado a partir dos parâmetros de sintonia do controlador, conforme descrito pela seção 3.2, pode ser representado pelo modelo:

$$\frac{2.6}{6.3s+1} \quad (4.3)$$

4.1.1 Antes da Alteração do Tempo Morto

O tamanho da janela foi definido, a partir do critério da frequência em que o tempo morto (TD) afeta o EMA, como sendo aproximadamente 300 segundos. A Figura 4.3 mostra o comportamento do EMA em todo o intervalo da simulação e a Figura 4.4 mostra o comportamento para a janela escolhida para aplicar a metodologia.

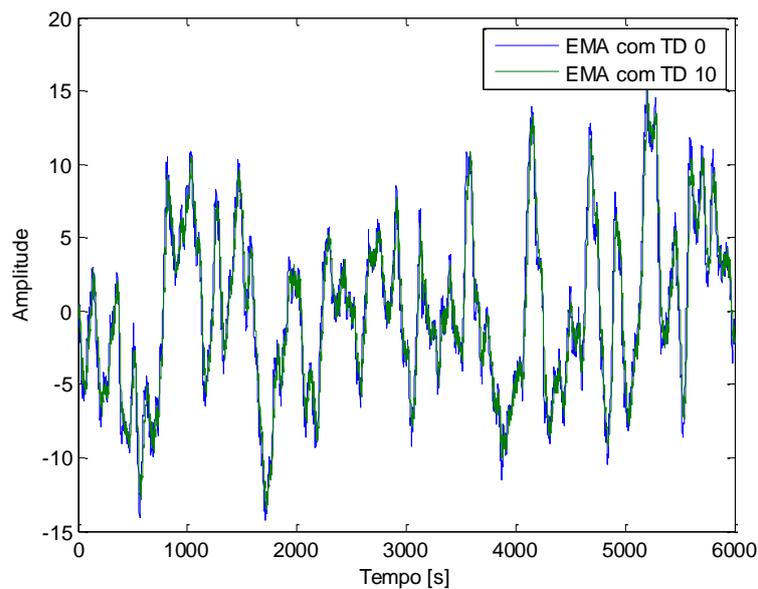


Figura 4.3: Comportamento do EMA durante o intervalo da simulação para o modelo inicial para diferentes tempos mortos.

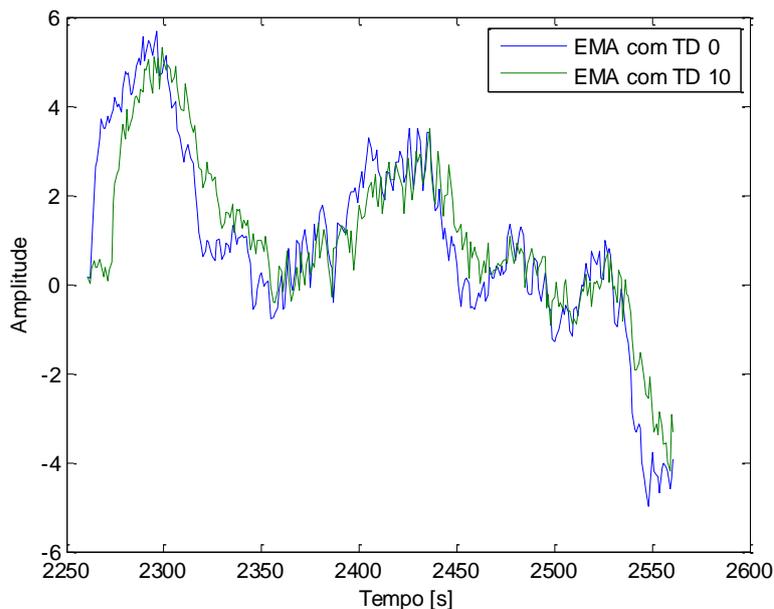


Figura 4.4: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.

Nas Figura 4.5 e Figura 4.6 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância, respectivamente. Verifica-se uma forte tendência de formação de um mínimo global próximo do tempo morto correto do sistema (1.5s) na função objetivo de coeficiente de determinação. Contudo, este mínimo não está claramente visível em virtude da não convexidade da curva.

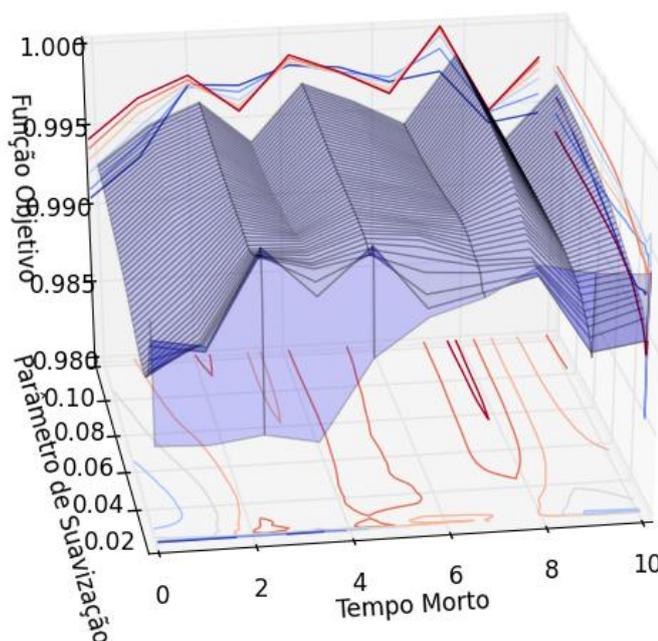


Figura 4.5: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.

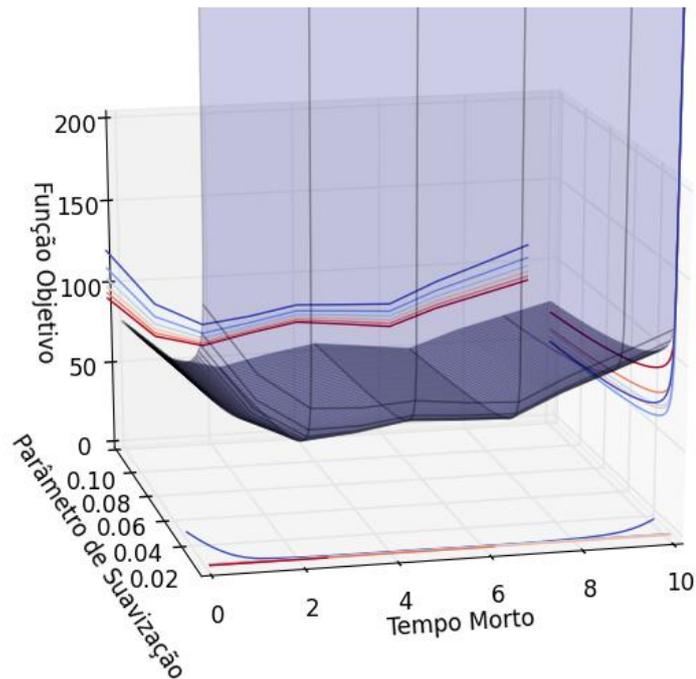


Figura 4.6: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.

Conforme sugerido no fluxograma da Figura 3.27, considerando que os tempos mortos indicados pelas duas funções objetivo divergiram, é necessária uma alteração no modelo. Assim, levando em conta as premissas discutidas, o ganho do modelo base foi modificado para 0.14 e conseqüentemente uma redução da razão sinal ruído. O comportamento do EMA, que pode ser visualizado na Figura 4.7, foi alterado de forma significativa. O resultado de tal modificação foi uma melhoria visível no comportamento da função objetivo pela formação de um mínimo global nítido, especialmente na função de coeficiente de determinação. As Figura 4.8 e Figura 4.9 mostram os comportamentos após modificação do modelo inicial. Após a modificação o tempo morto calculado pela metodologia foi aproximadamente 1.5s.

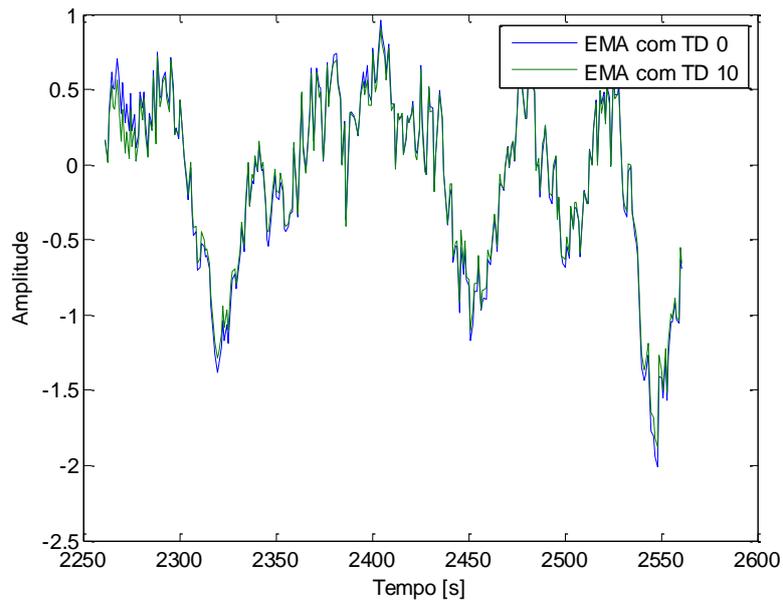


Figura 4.7: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.

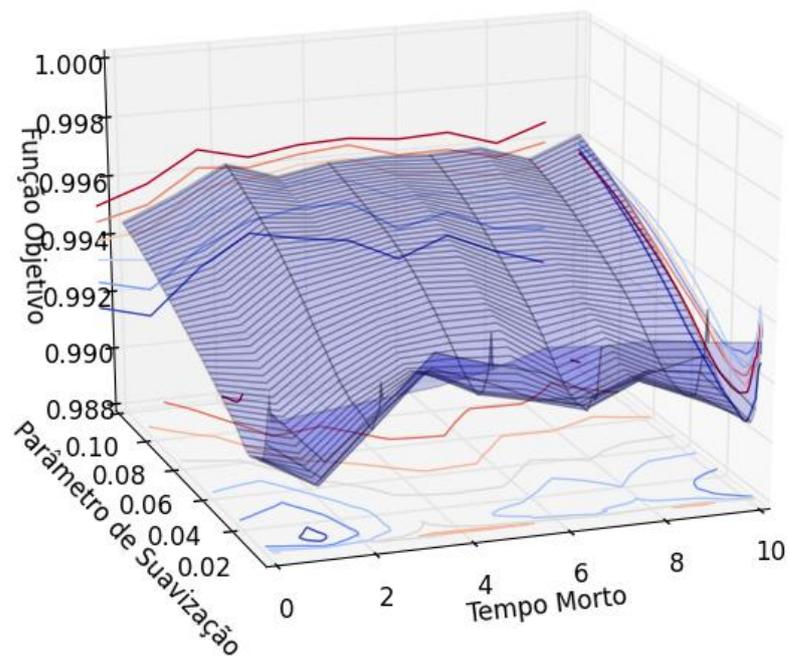


Figura 4.8: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.

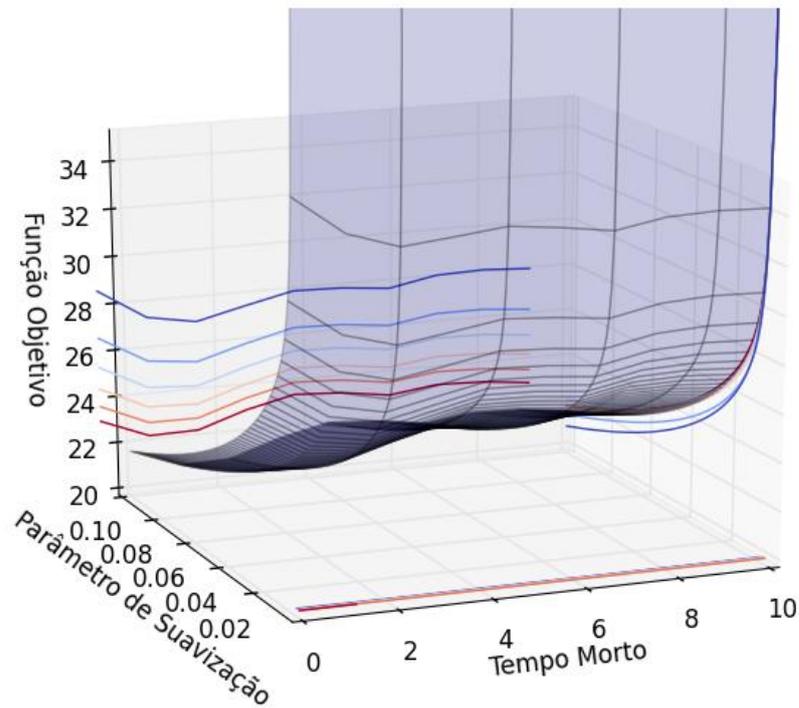


Figura 4.9: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.

A Figura 4.10 mostra o comportamento do EMA e da *spline* suavizante com parâmetro de suavização 0.03, próximo do mínimo global, para o tempo morto correto do sistema.

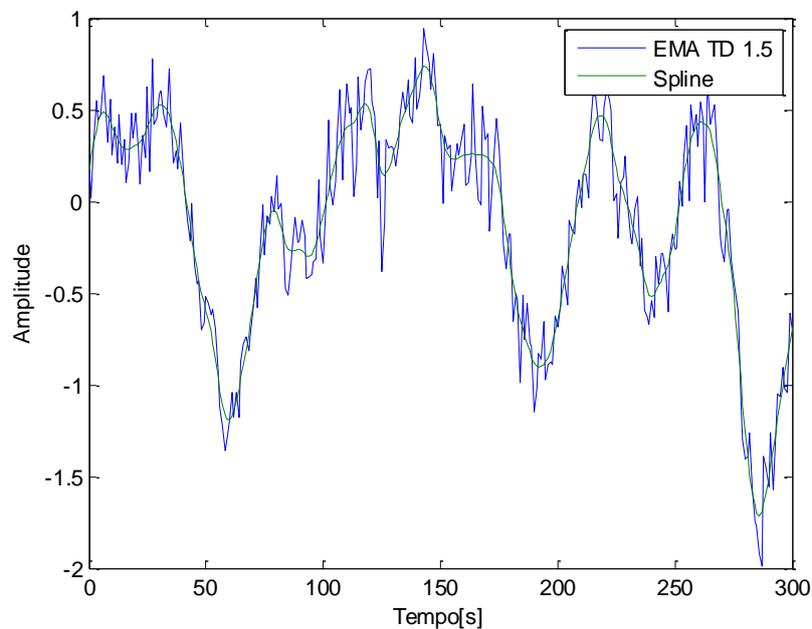


Figura 4.10: Comportamento do EMA e da *spline* suavizante com o tempo morto correto.

4.1.2 Após Alteração do Tempo Morto

O tamanho da janela foi definido como aproximadamente 300 segundos a partir do critério da frequência. A Figura 4.11 mostra o comportamento do EMA para a janela escolhida para aplicar a metodologia.

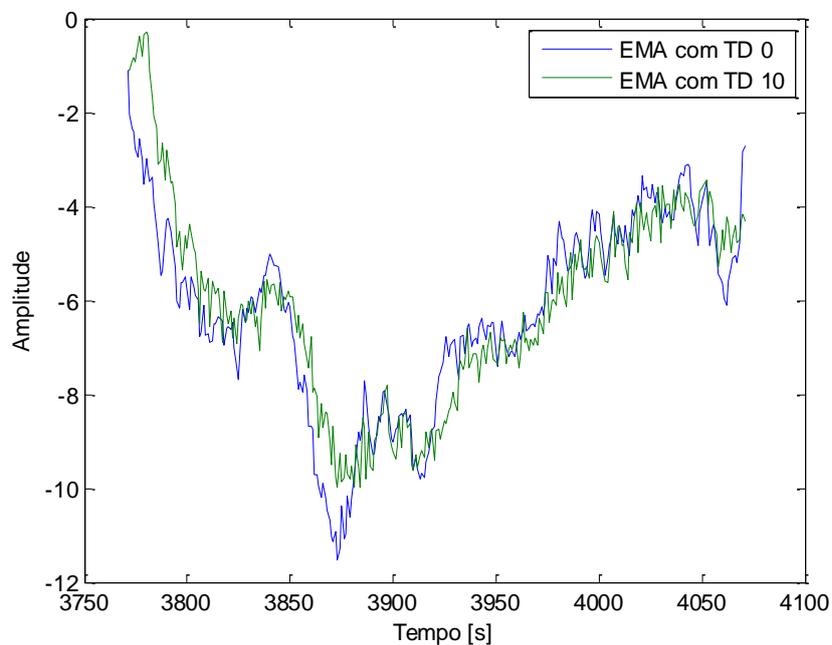


Figura 4.11: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.

Nas Figura 4.12 e Figura 4.13 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância, respectivamente. Verifica-se um mínimo global próximo do tempo morto correto do sistema (3s) na função objetivo de coeficiente de determinação.

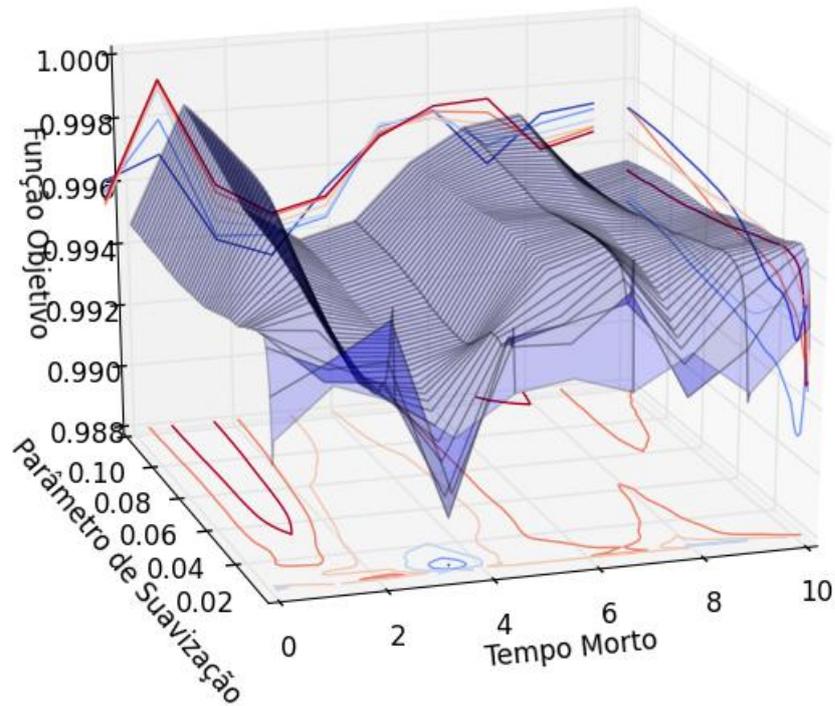


Figura 4.12: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.

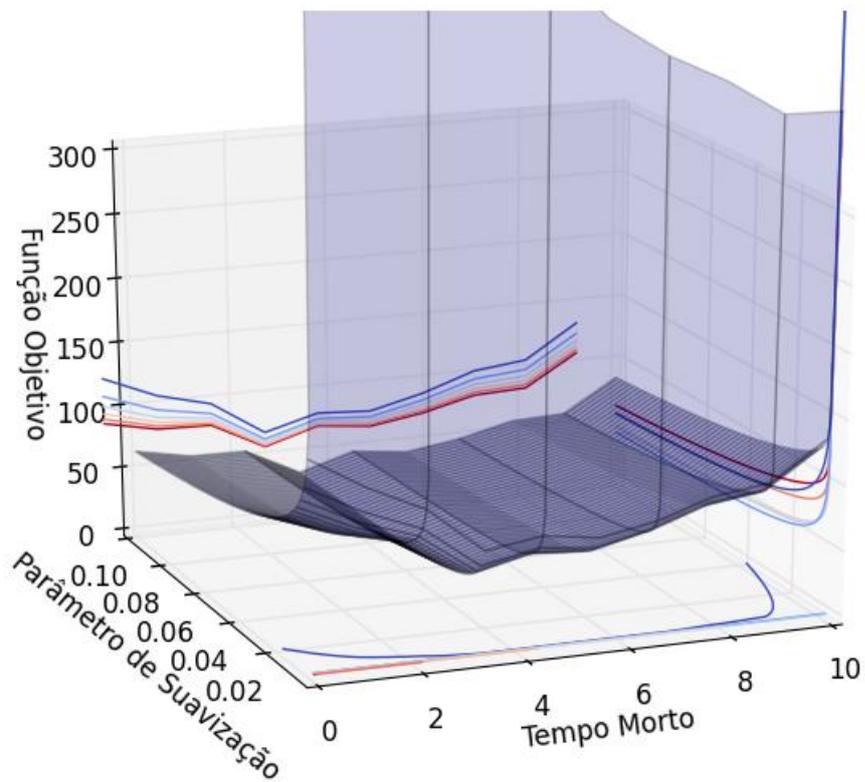


Figura 4.13: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.

Com uma pequena alteração no ganho do modelo para 1.6 o comportamento do EMA, não sofreu alterações bruscas. Apenas realçou a presença do mínimo global das curvas, que podem ser visualizadas em Figura 4.14 e Figura 4.15.

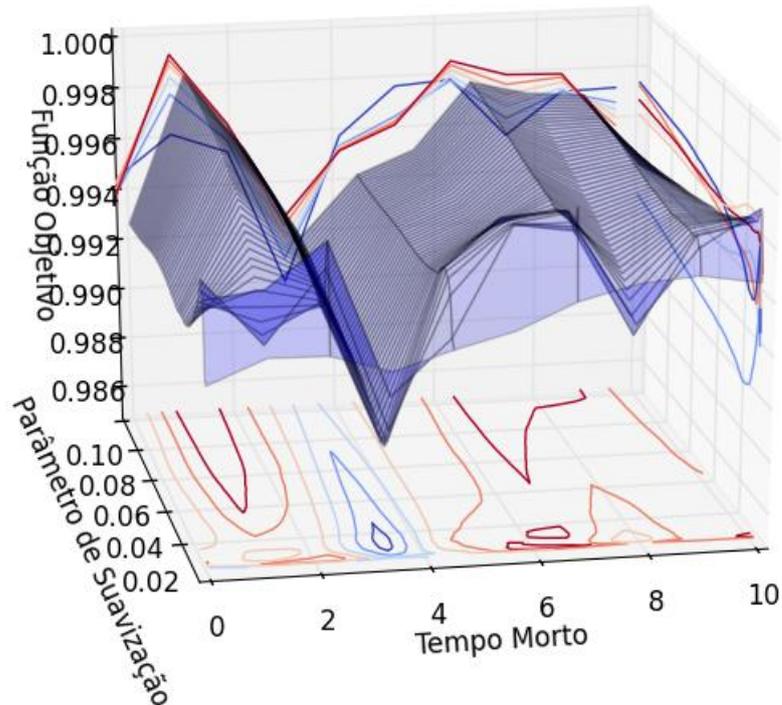


Figura 4.14: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.

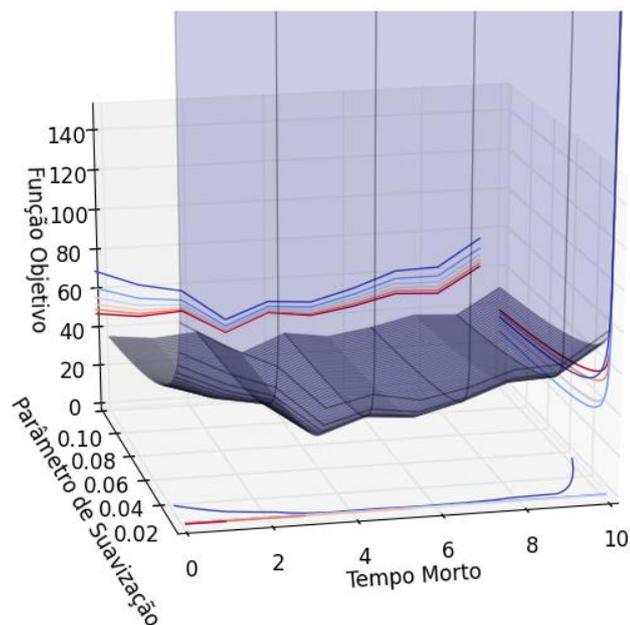


Figura 4.15: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.

Na Figura 4.16 pode ser o comportamento do EMA e da *spline* suavizante com parâmetro de suavização 0.03, próximo do mínimo global, para o tempo morto correto do sistema.

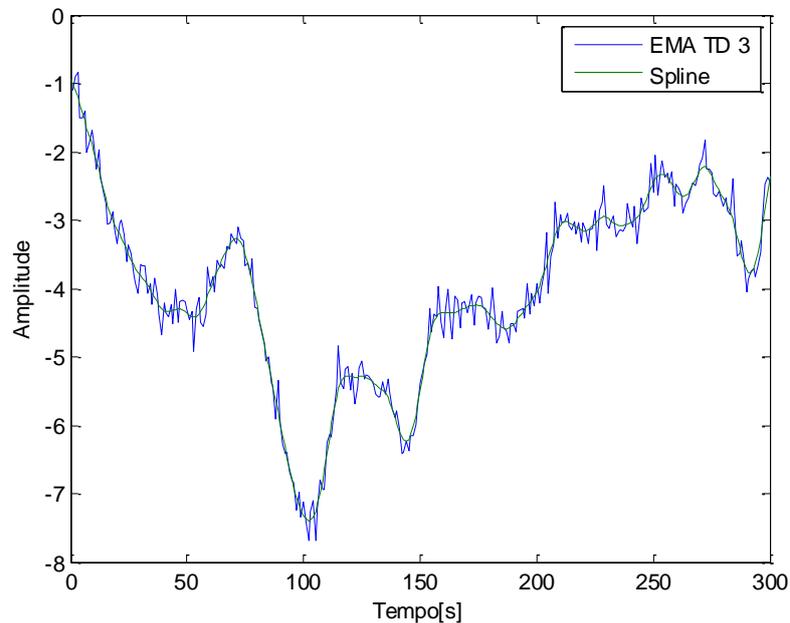


Figura 4.16: Comportamento do EMA e da *spline* suavizante com o tempo morto correto.

A partir dos resultados pode se concluir que a metodologia foi capaz de capturar a modificação do tempo morto do sistema de forma eficaz. A estimativa do tempo morto foi satisfatória e alterações no modelo foram capazes de melhorar o formato da função objetivo. Neste caso em particular, a metodologia apresentou grande sensibilidade, de maneira que foi possível estimar o tempo morto fracionário do sistema (1.5s). Este aspecto é importante uma vez que a maior parte das técnicas da literatura estima o tempo morto como sendo um múltiplo de amostragem (i.e não fracionário).

4.2 Planta de Segunda Ordem – Tempo Morto Variável

Com o objetivo de avaliar a metodologia proposta para fins de monitoramento de malhas de controle o presente estudo de caso simula situações em que o tempo morto do sistema possa ser alterado em virtude de distúrbios ou alteração da dinâmica do processo. O objetivo deste estudo de caso é avaliar a metodologia quando o sistema é de segunda ordem. A planta é representada pela função de transferência abaixo:

$$\frac{0.5e^{-\theta s}}{36s^2+6s+1} \quad (4.4)$$

A simulação tem ao todo 6000 segundos com tempo de amostragem de 1 segundo. O tempo morto inicial era de 20 segundos e a alteração no tempo morto de sistema ocorreu no tempo de 3000 segundos para o valor de 15 segundos.

O controlador utilizado foi um PID com ganho proporcional de 1.118, constante de tempo integral de 7.73 e constante de tempo derivativa de 0.089. O ruído de medição é um sinal randômico branco com intensidade estipulada através do índice SNR (Wang & Zhang 2001), definido como 15%.

O sinal que representa o distúrbio não medido pode ser visualizado na Figura 4.17, ele foi criado a partir de um ruído branco interpolado através de uma função *spline*. A Figura 4.18 mostra a variável manipulada e a variável controlada para o estudo de caso 4.2.

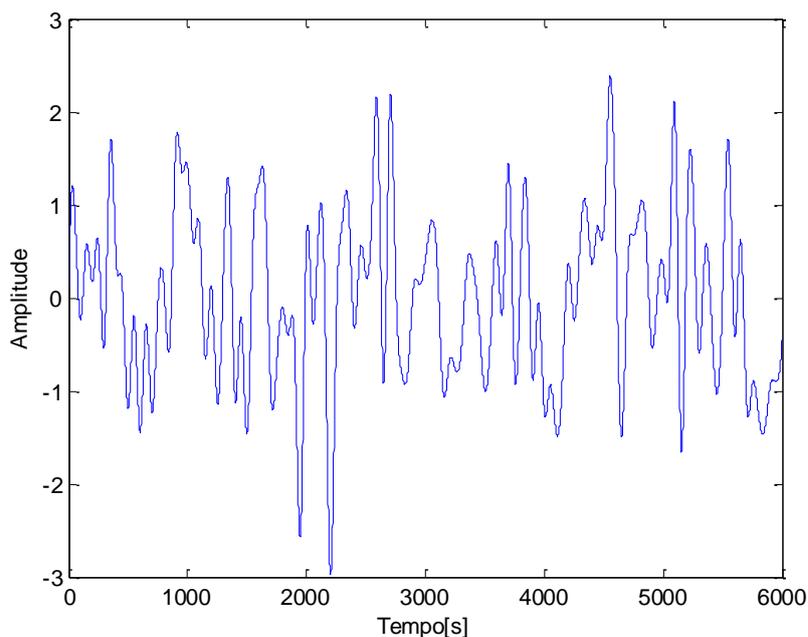


Figura 4.17: Sinal que representa o distúrbio não medido.

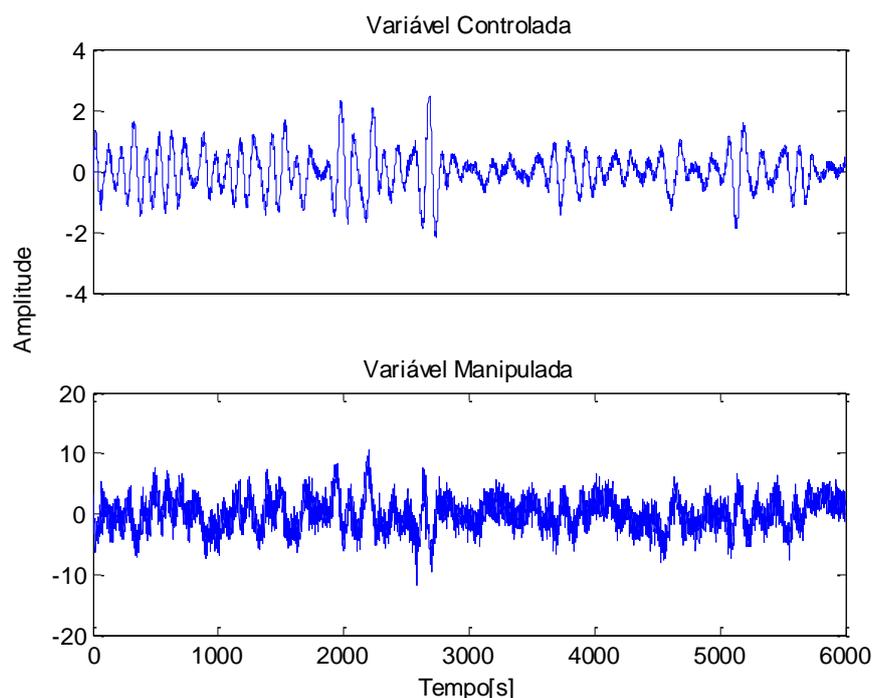


Figura 4.18: Variável controlada e variável manipulada.

Neste estudo de caso a metodologia, como descrita no fluxograma 3.27, foi aplicada em uma janela de dados antes da mudança do tempo morto e outra vez em outra janela de dados após a mudança do tempo morto, a fim de verificar a capacidade de capturar de forma correta a mudança do parâmetro.

Um dos objetivos deste estudo de caso é verificar o impacto da ordem do modelo no resultado, para tanto será considerado um modelo de primeira ordem e um de segunda. Os modelos iniciais, calculados a partir do controlador, podem ser representados pelas funções de transferência:

$$\frac{0.89}{7.34s+1} \quad (4.5)$$

$$\frac{0.89}{59.9s^2+7.34s+1} \quad (4.6)$$

4.2.1 Antes da Alteração do Tempo Morto

O tamanho da janela foi definido, a partir do critério da frequência em que o tempo morto afeta o EMA, como sendo aproximadamente 300 segundos. A Figura 4.19 mostra o comportamento do EMA em todo o intervalo da simulação para os modelos iniciais e a Figura 4.20 mostra o comportamento para a janela escolhida para aplicar a metodologia.

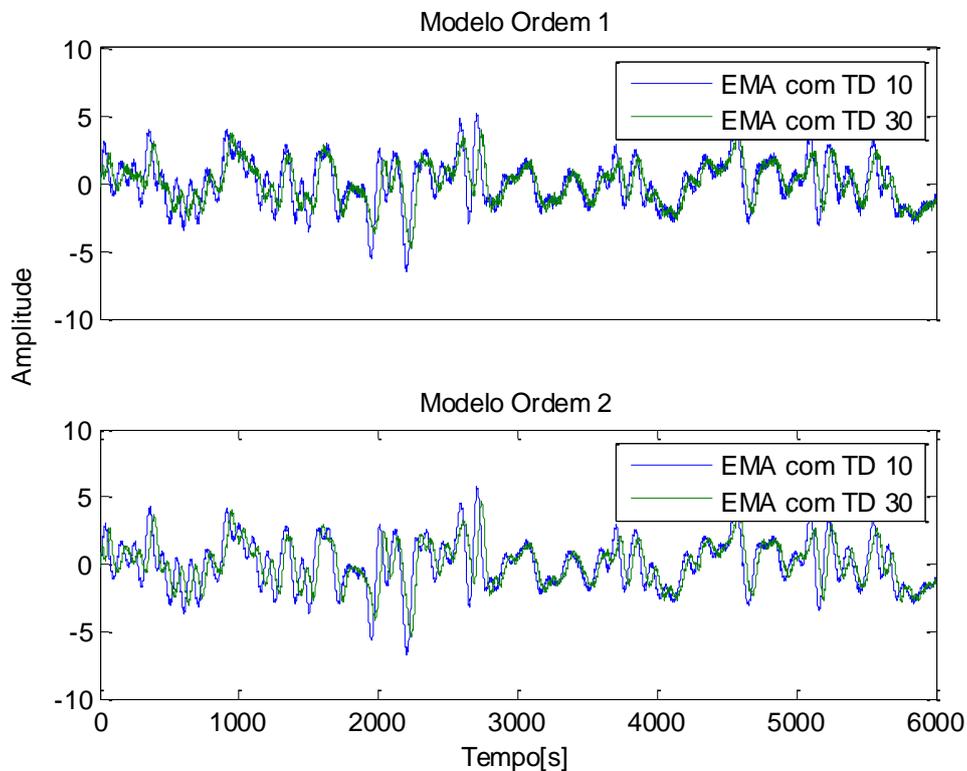


Figura 4.19: Comportamento do EMA durante o intervalo da simulação para os modelos iniciais para diferentes tempos mortos.

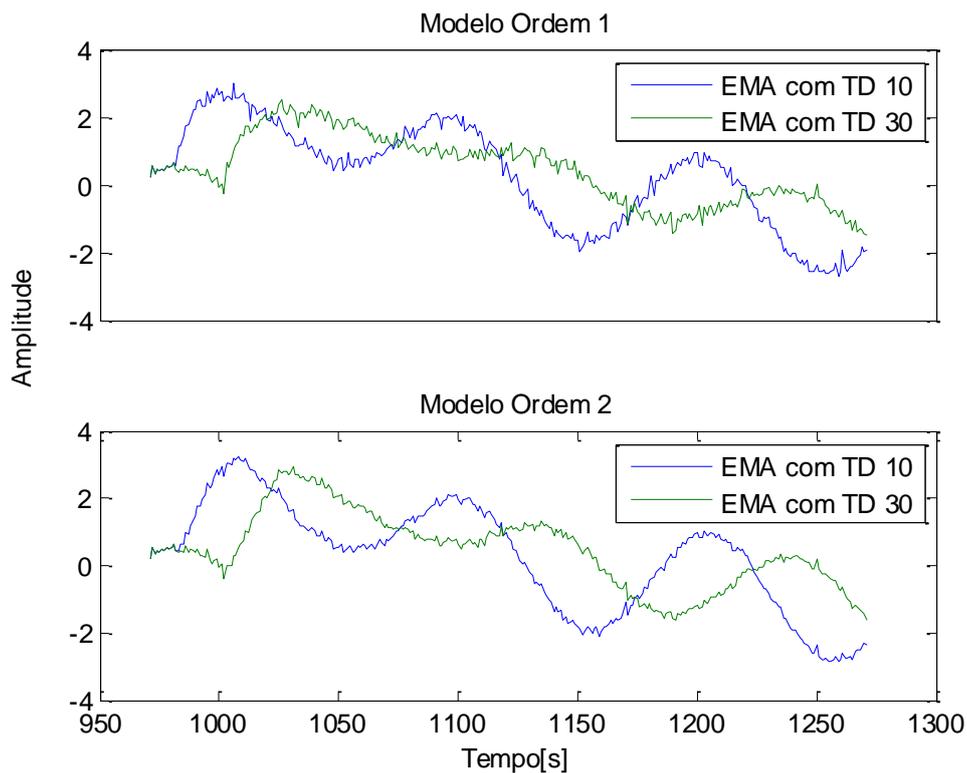


Figura 4.20: Comportamento do EMA na janela de aplicação da metodologia para os modelos iniciais para diferentes tempos mortos.

Nas Figura 4.21 e Figura 4.22 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância para o modelo de primeira ordem, respectivamente. Verifica-se uma forte tendência de formação de um mínimo global próximo do tempo morto correto do sistema (20s) na função objetivo de coeficiente de determinação. Contudo, este mínimo não está claramente visível em virtude da não convexidade da curva. Neste caso, para um modelo de primeira ordem, houve certo desvio em relação ao tempo morto correto.

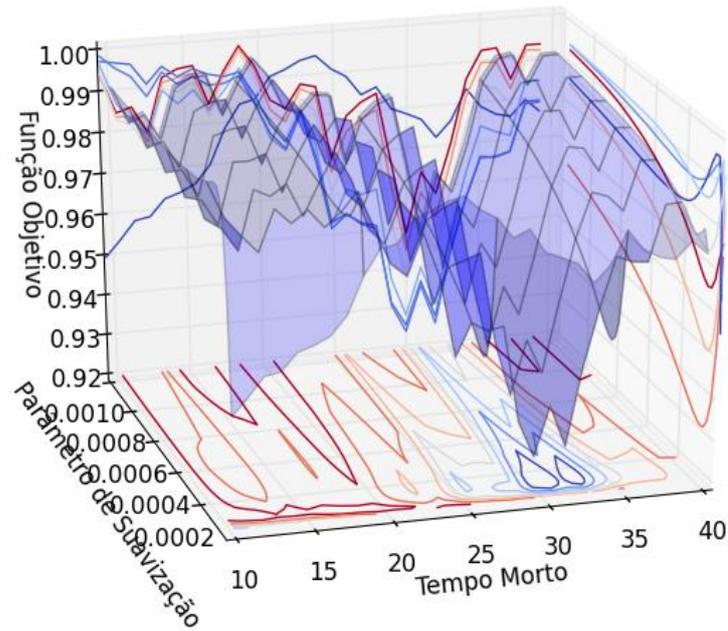


Figura 4.21: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 1.

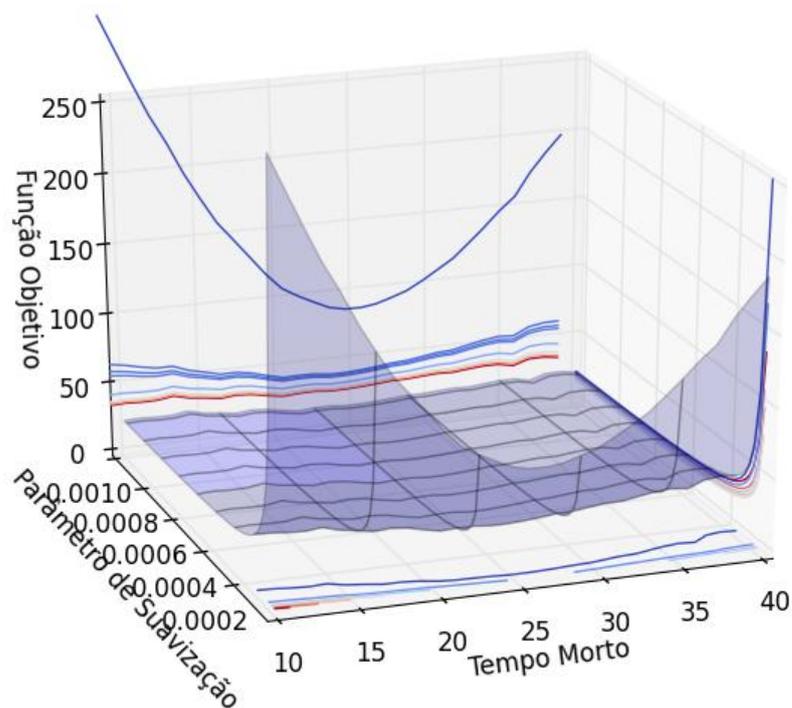


Figura 4.22: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo ordem 1.

As Figura 4.23 e Figura 4.24 mostram as funções objetivo de coeficiente de determinação e variância para o modelo de segunda ordem, respectivamente. Verifica-se uma forte tendência de formação de um mínimo global próximo do tempo morto correto do sistema (20s) na função objetivo de coeficiente de determinação. Ainda, fica visível

uma melhoria no formato da função objetivo em relação ao modelo de primeira ordem. Este comportamento demonstra que há certa dependência do conhecimento da ordem verdadeira do sistema. Contudo, há casos, como na Figura 4.21, onde uma aproximação de ordem mais baixa pode ser suficiente, isto sugere que seria possível, com uma etapa de otimização do modelo base, obter um resultado satisfatório utilizando apenas modelos de primeira ordem.

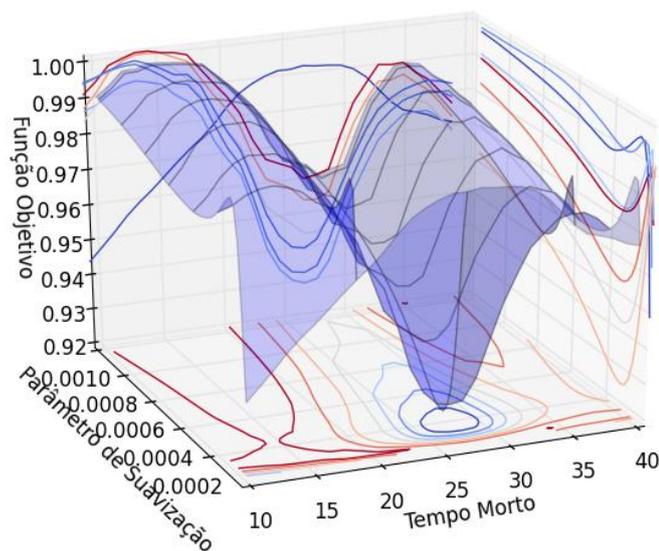


Figura 4.23: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 2.

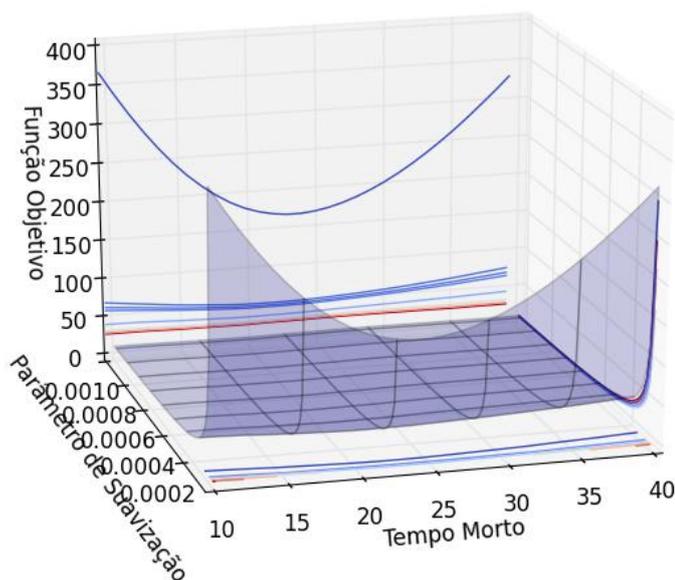


Figura 4.24: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo ordem 2.

A função objetivo de variância foi capaz de estimar o tempo correto do sistema para parâmetros de suavização baixos (próximos de 0.0002).

4.2.2 Após Alteração do Tempo Morto

O tamanho da janela foi definido como aproximadamente 300 segundos a partir do critério da frequência. A Figura 4.25 mostra o comportamento do EMA para a janela escolhida para aplicar a metodologia.

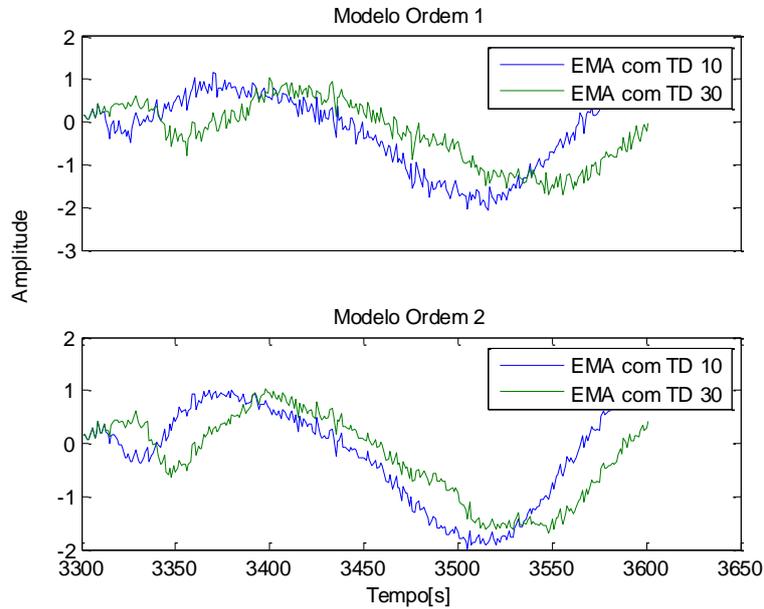


Figura 4.25: Comportamento do EMA na janela de aplicação da metodologia para os modelos iniciais para diferentes tempos mortos.

Nas Figura 4.26 e Figura 4.27 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância para modelo de primeira ordem, respectivamente. Verifica-se um mínimo global próximo do tempo morto correto do sistema (15s) na função objetivo de coeficiente de determinação.

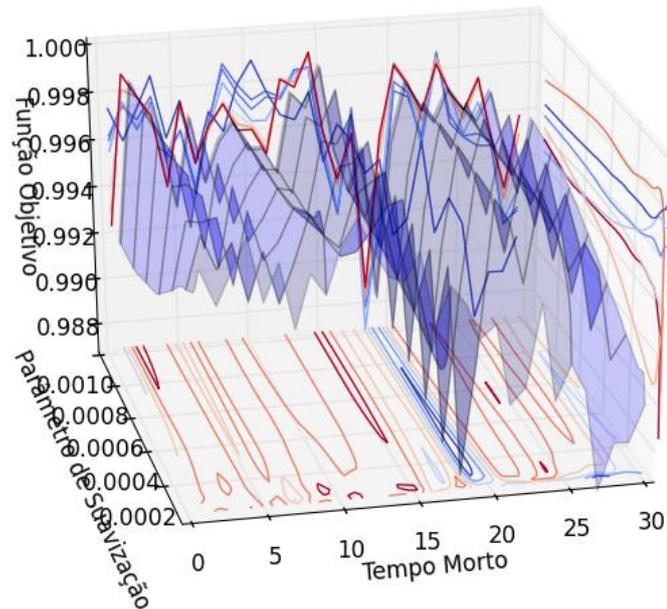


Figura 4.26: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 1.

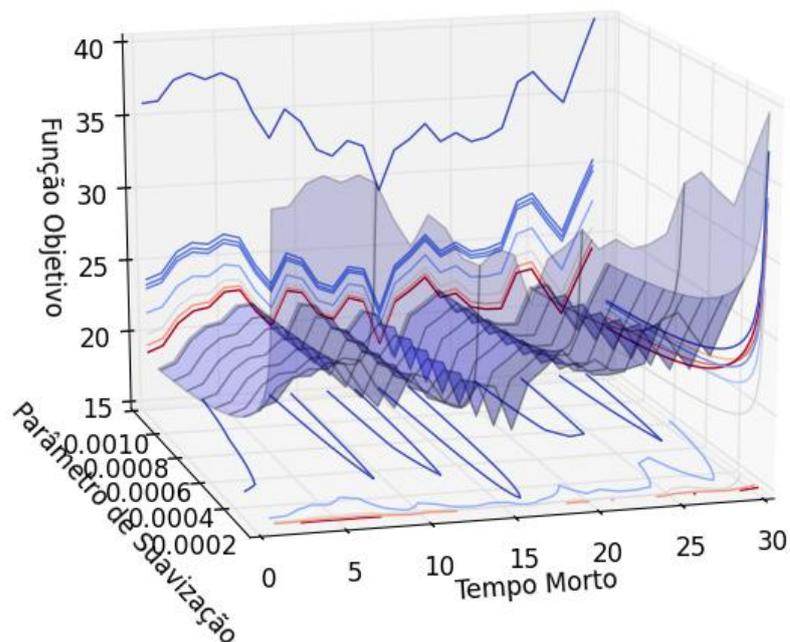


Figura 4.27: Comportamento da função objetivo da variância versus parâmetro de suavização e tempo morto para modelo ordem 1.

As Figura 4.28 e Figura 4.29 mostram as funções objetivo de coeficiente de determinação e variância para o modelo de segunda ordem, respectivamente. Verifica-se uma forte tendência de formação de um mínimo global próximo do tempo morto correto do sistema (15s) na função objetivo de variância para parâmetros de suavização baixos (próximos de 0.0002). Novamente, fica visível uma melhoria no formato da função objetivo em relação ao modelo de primeira ordem.

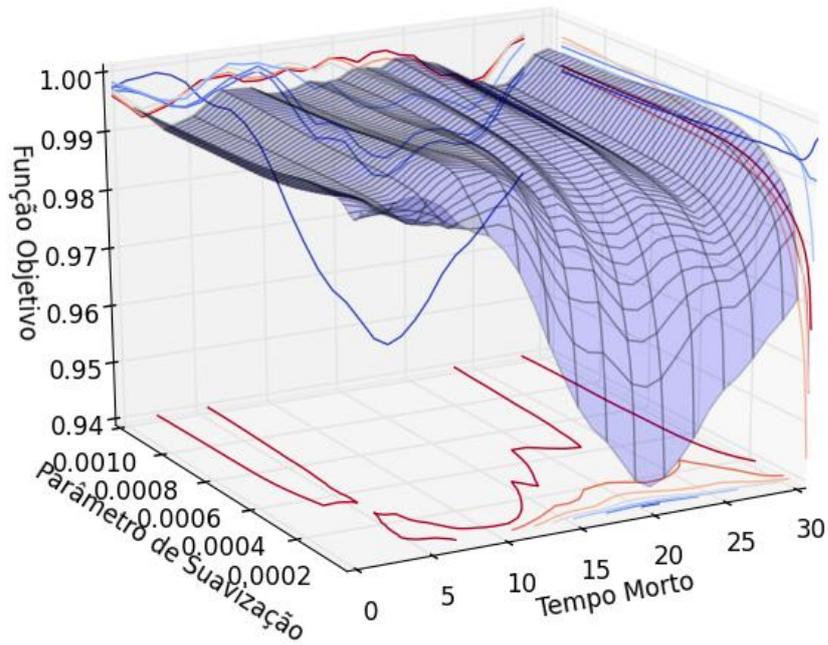


Figura 4.28: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo ordem 2.

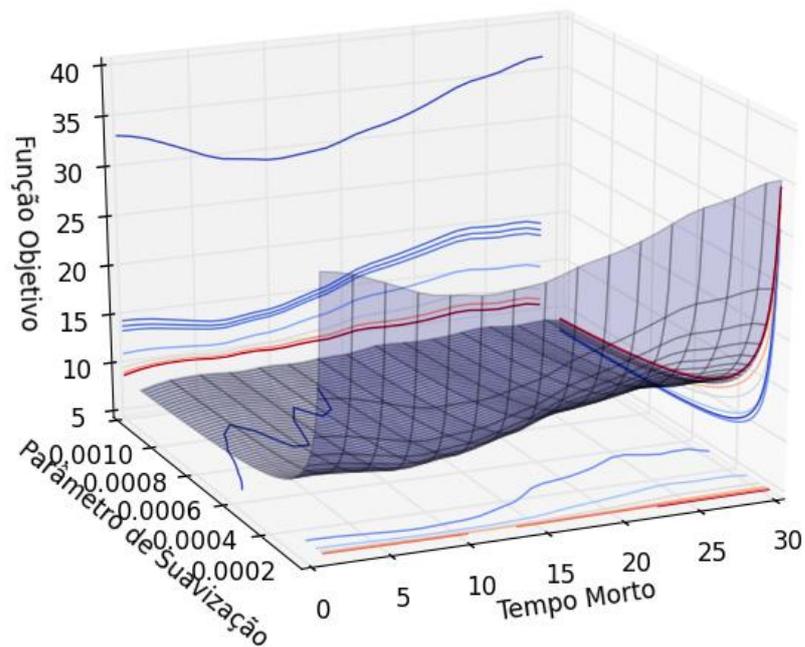


Figura 4.29: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo ordem 2.

A função objetivo de coeficiente de determinação com modelo de ordem 2 teve uma melhoria no formato em relação ao modelo de primeira ordem. Contudo não foi capaz de capturar com precisão do tempo morto correto de 15s. Estima-se que isto tenha ocorrido pelo impacto da alteração do modelo, ou pelo simples fato de que o modelo utilizado não foi o mais adequado para a situação, uma vez que a função objetivo não forma um mínimo global.

4.3 Planta de Primeira Ordem Lenta – Tempo Morto Variável

O objetivo deste estudo de caso é avaliar a metodologia quando a dinâmica do sistema é lenta. A planta é representada pela função de transferência abaixo:

$$\frac{1e^{-\theta s}}{200s+1} \quad (4.7)$$

A simulação tem ao todo 6000 segundos com tempo de amostragem de 1 segundo. O tempo morto inicial era de 150 segundos e a alteração no tempo morto de sistema ocorreu no tempo de 3000 segundos para o valor de 75 segundos.

O controlador utilizado foi um PID com ganho proporcional de 0.05, constante de tempo integral de 9.2 e constante de tempo derivativa de 0.07. O ruído de medição é um sinal randômico branco com intensidade estipulada através do índice SNR (Wang & Zhang 2001), definido como 15%.

O sinal que representa o distúrbio não medido pode ser visualizado na Figura 4.30, ele foi criado a partir de um ruído branco colorido através de uma função de transferência de primeira ordem com ganho 3 e constante de tempo 550. A Figura 4.31 mostra a variável manipulada e a variável controlada para o estudo de caso 4.3.

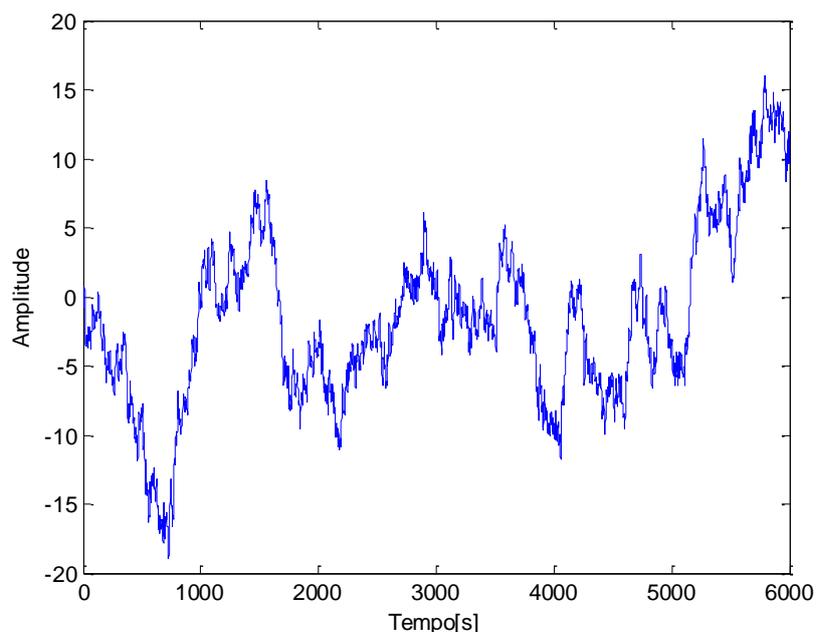


Figura 4.30: Sinal que representa o distúrbio não medido.

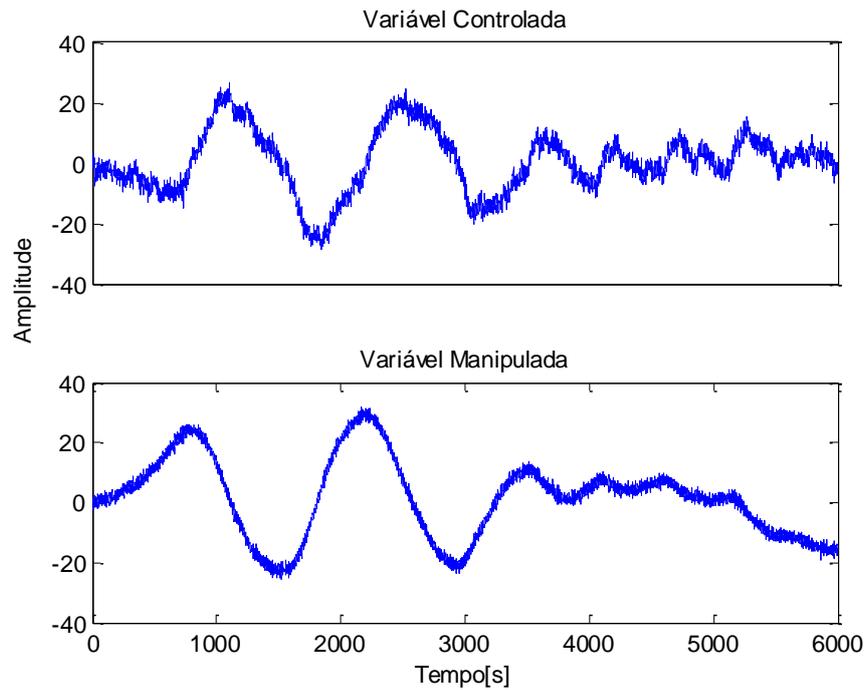


Figura 4.31: Variável controlada e variável manipulada.

Neste estudo de caso a metodologia, como descrita no fluxograma da Figura 3.27, foi aplicada em uma janela de dados antes da mudança do tempo morto e outra vez em outra janela de dados após a mudança do tempo morto, a fim de verificar a capacidade de capturar de forma correta a mudança do parâmetro.

O modelo, calculado a partir do controlador, pode ser representado pela função de transferência:

$$\frac{20}{9.2s+1} \quad (4.8)$$

4.3.1 Antes da Alteração do Tempo Morto

O tamanho da janela foi definido, a partir do critério da frequência em que o tempo morto afeta o EMA, como sendo aproximadamente 1500 segundos. A Figura 4.32 mostra o comportamento do EMA em todo o intervalo da simulação para o modelo inicial e a Figura 4.33 mostra o comportamento para a janela escolhida para aplicar a metodologia.

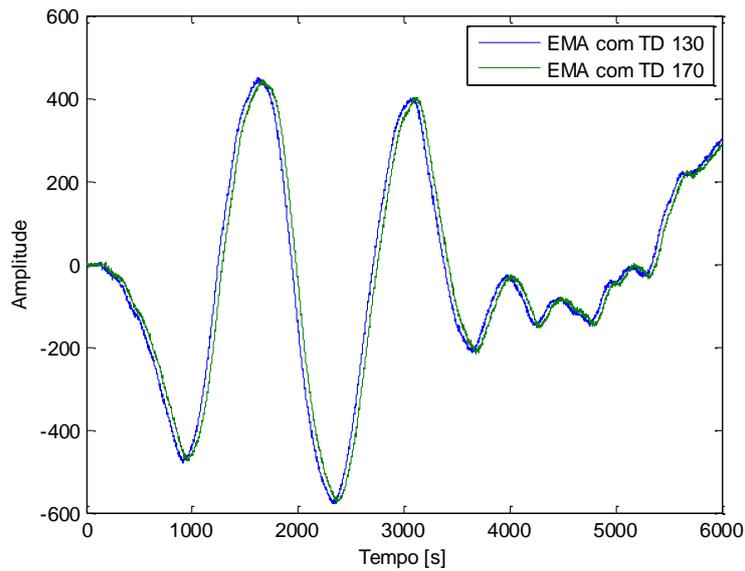


Figura 4.32: Comportamento do EMA durante o intervalo da simulação para o modelo inicial para diferentes tempos mortos.

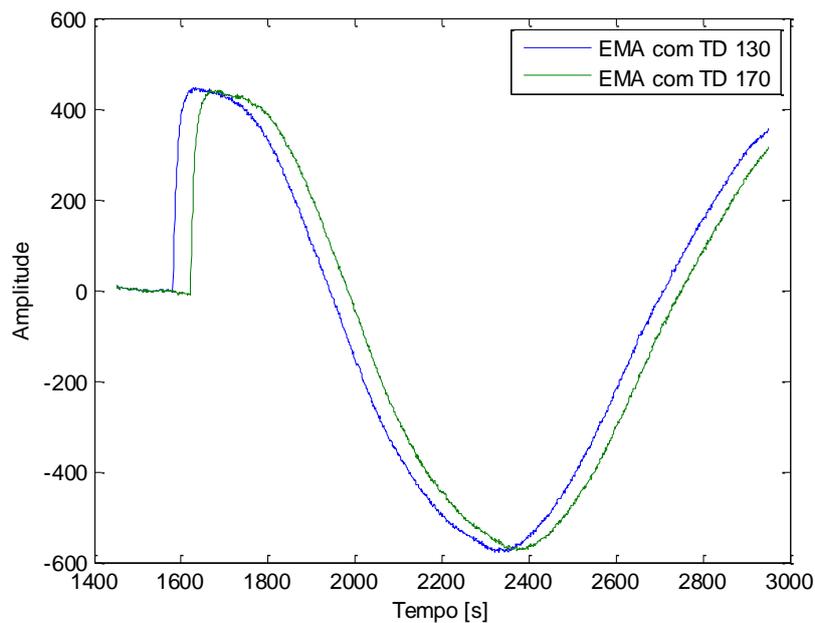


Figura 4.33: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.

Nas Figura 4.34 e Figura 4.35 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância para o modelo inicial, respectivamente. O que se observa é uma falta de sensibilidade na função objetivo de coeficiente de determinação.

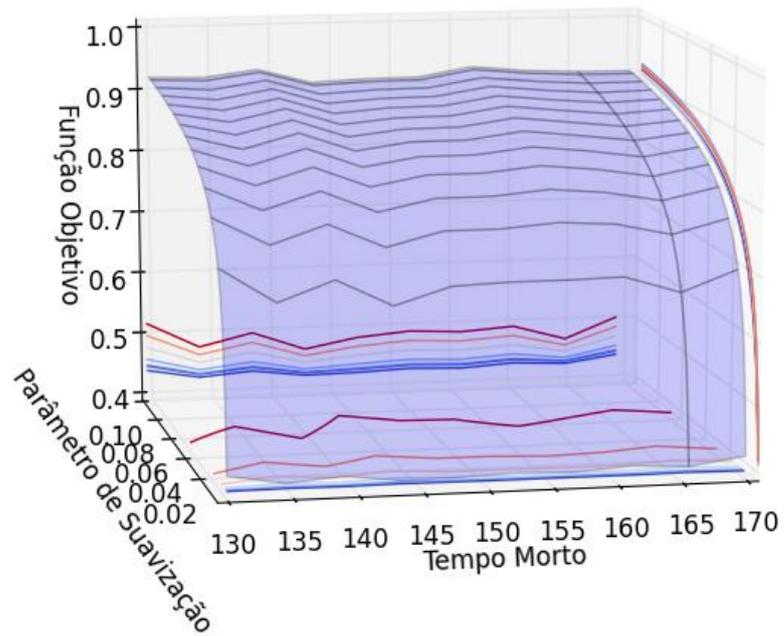


Figura 4.34: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para modelo inicial.

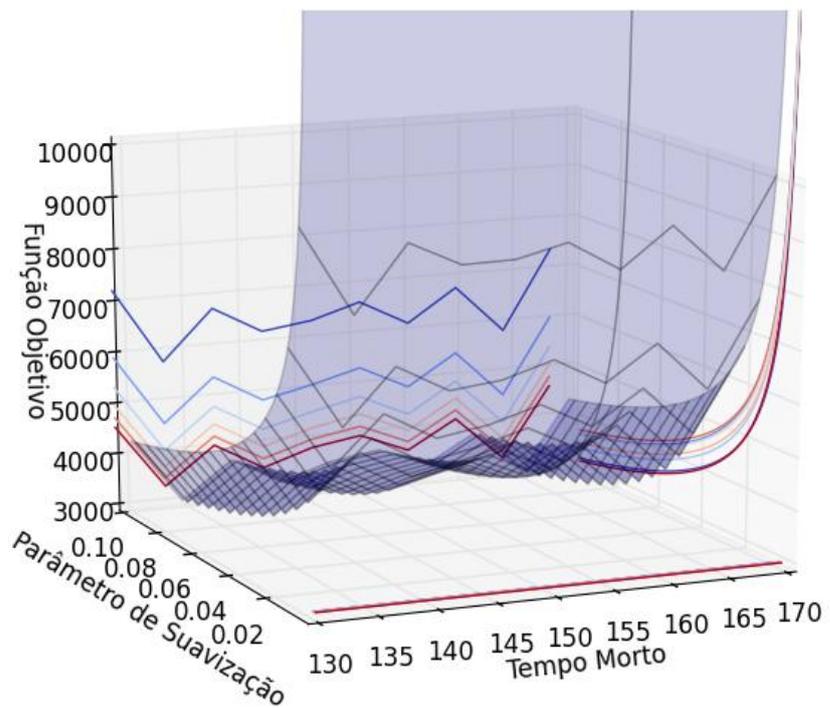


Figura 4.35: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para modelo inicial.

A falta de sensibilidade na função objetivo pode ser contornada através de uma alteração no modelo inicial. Sendo assim, reduzindo o ganho para 0.5 a razão sinal ruído (com suavização 0.0001) passou de 450 para aproximadamente 50. A Figura 4.36 mostra o comportamento do EMA e Figura 4.37 mostra o comportamento da função objetivo de coeficiente de determinação após alteração do modelo inicial. Destaca-se que esta etapa de alteração do modelo ainda deve ser estudada de forma a se obter o modelo que favoreça a função objetivo.

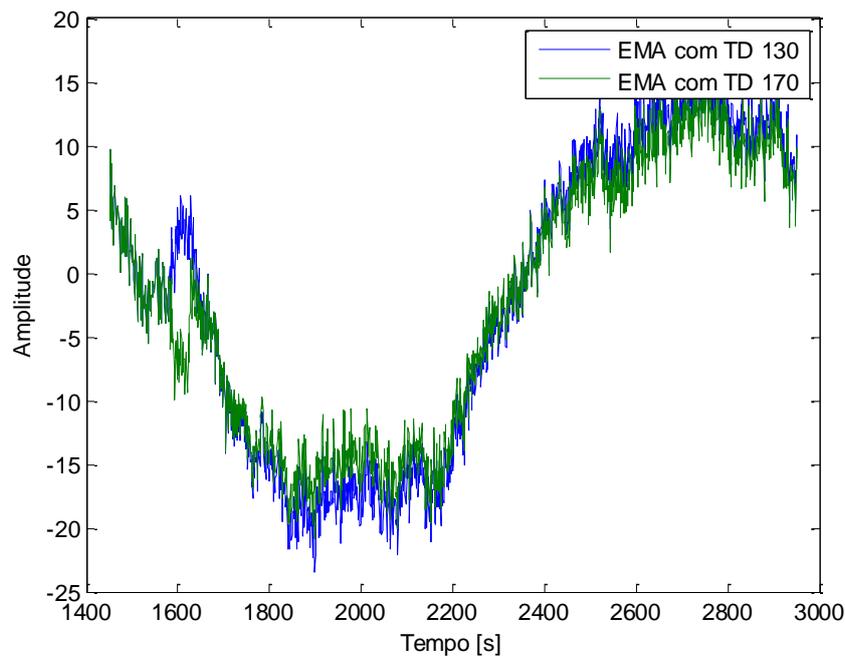


Figura 4.36: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.

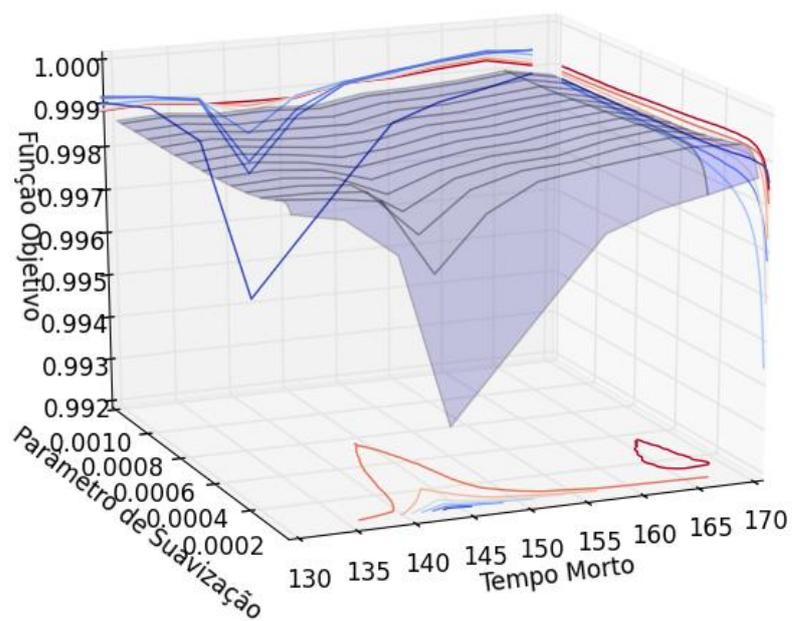


Figura 4.37: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo.

Na Figura 4.38 segue o comportamento do EMA e da *spline* suavizante para o parâmetro de suavização 0.00001 e para o tempo morto correto.

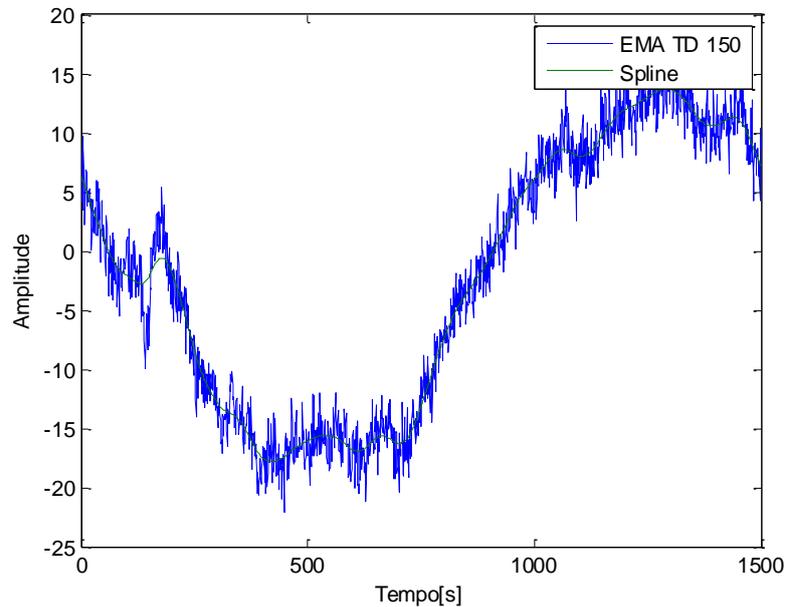


Figura 4.38: Comportamento do EMA e da *spline* suavizante próximo do mínimo global da função objetivo.

4.3.2 Após Alteração do Tempo Morto

O tamanho da janela foi definido como aproximadamente 1500 segundos a partir do critério da frequência. A mostra o comportamento do EMA para a janela escolhida para aplicar a metodologia.

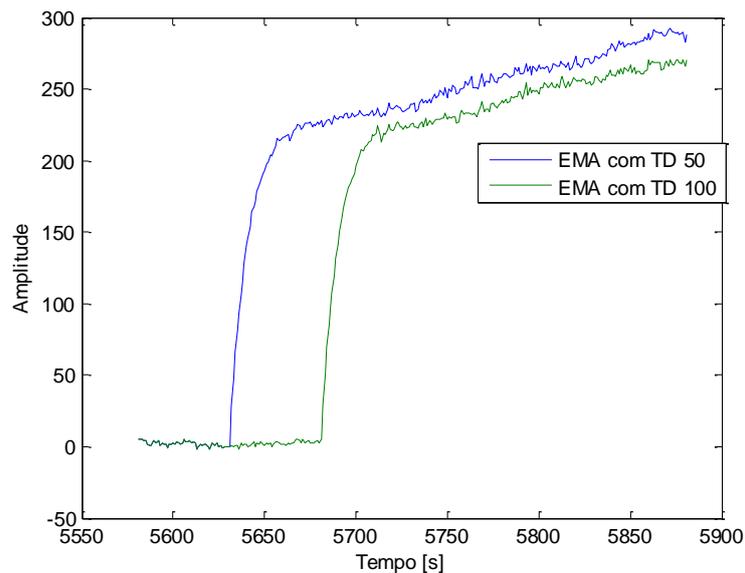


Figura 4.39: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.

Nas Figura 4.40 e Figura 4.41 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância para modelo de primeira ordem, respectivamente. Verifica-se um mínimo global próximo do tempo morto correto do sistema (75s) na função objetivo de coeficiente de determinação e na de variância.

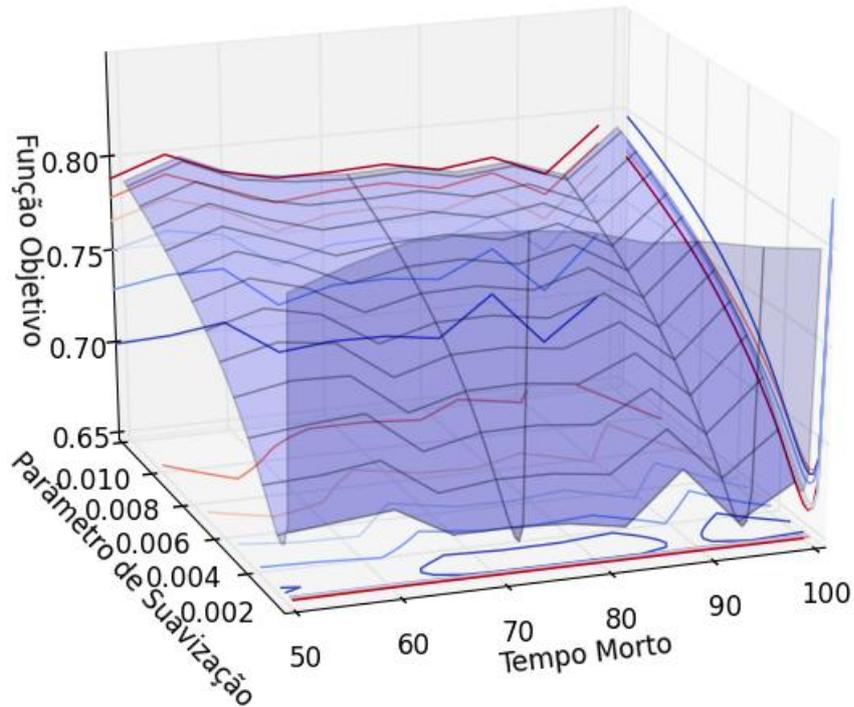


Figura 4.40: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo inicial.

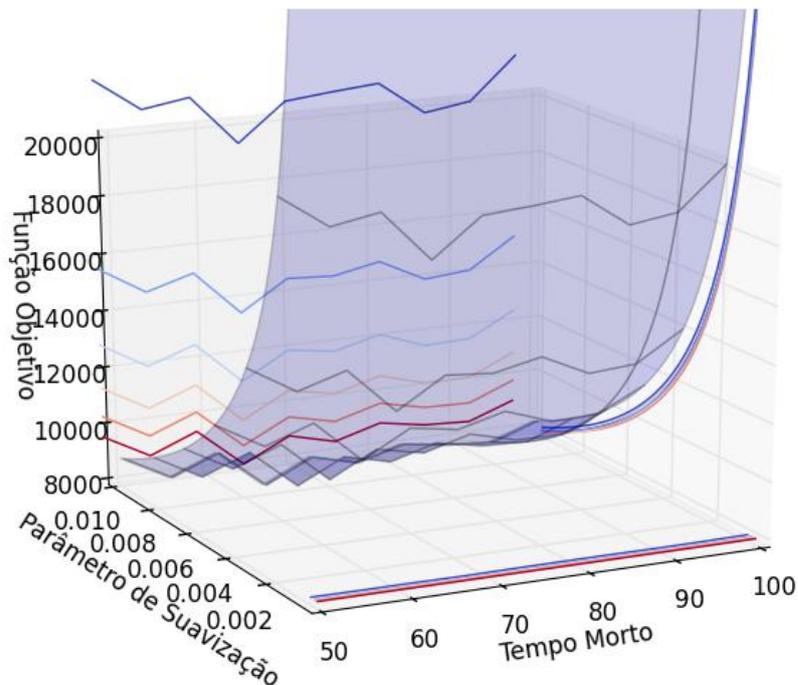


Figura 4.41: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para o modelo inicial.

Reduzindo o ganho para 1 a razão sinal ruído (com suavização 0.0001) passou de 2300 para aproximadamente 20. A Figura 4.42 mostra o comportamento do EMA e Figura 4.43 mostra o comportamento da função objetivo de coeficiente de determinação após alteração do modelo inicial. Nota-se que para este caso, pela não convexidade da função objetivo, o intervalo de busca do parâmetro tempo morto deve ser menor (em torno de 10 ou 20 tempos de amostragem). Intervalos de busca maiores iriam provocar erros na estimativa.

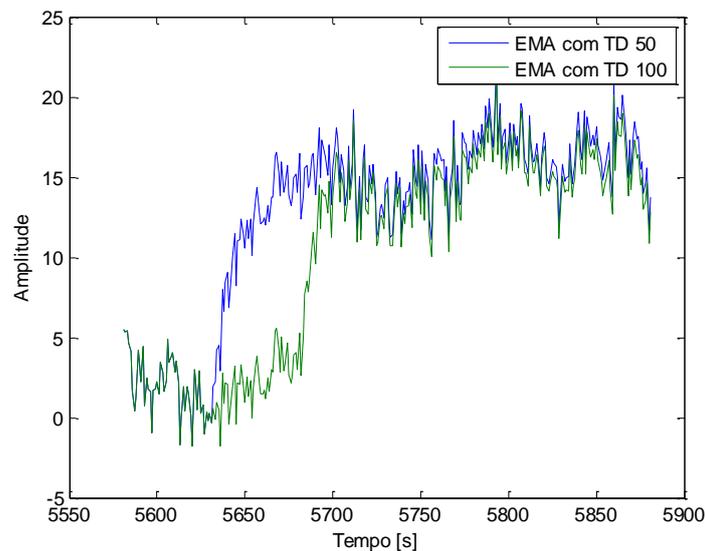


Figura 4.42: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.

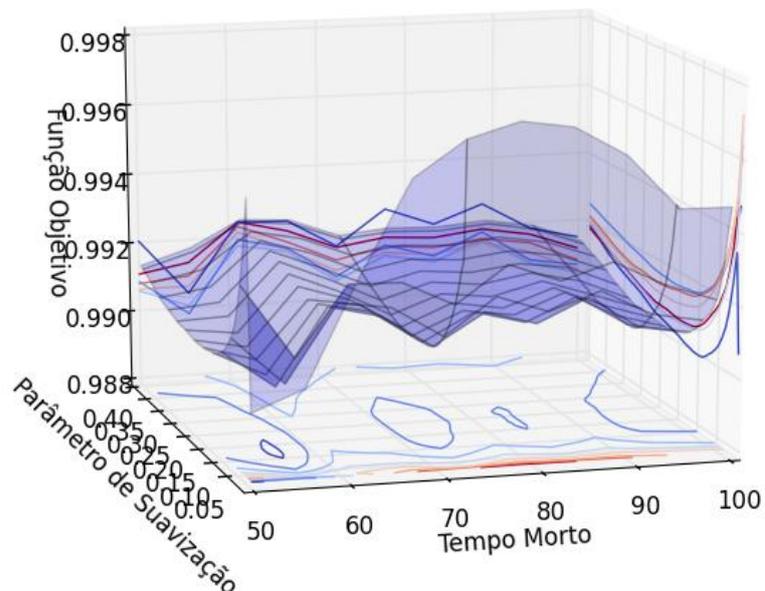


Figura 4.43: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo.

Na Figura 4.44 segue o comportamento do EMA e da *spline* suavizante para o parâmetro de suavização 0.1 e para o tempo morto correto.

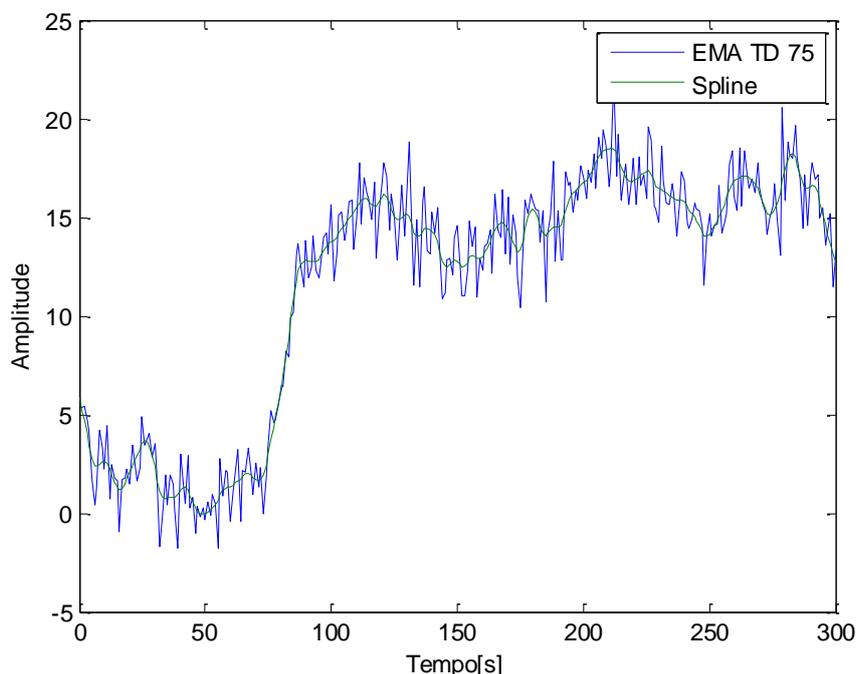


Figura 4.44: Comportamento do EMA e da *spline* suavizante próximo do mínimo global da função objetivo.

Nota-se que para este estudo de caso em particular a metodologia proposta sofreu maior impacto do modelo inicial. Isto pode estar relacionado com o fato da planta possuir dinâmica lenta. Mesmo assim, após modificações no modelo, foi possível estimar o tempo morto e capturar a sua modificação ao longo da simulação. Além disso, a não convexidade da função objetivo pode ser um fator limitante em situações onde não se tem conhecimento prévio de um intervalo de busca adequado para o parâmetro tempo morto, como sugere a Figura 4.43.

4.4 Avaliação exaustiva da metodologia

Com o intuito de avaliar a metodologia proposta frente a um grande conjunto de cenários, um estudo de caso exaustivo que combina diferentes padrões de plantas e distúrbios, sob diferentes condições de sintonia e níveis de ruído de medição é proposto. A Tabela 4.1 mostra as 8 plantas selecionadas. No estudo de caso exaustivo, desta seção, é avaliada apenas a função objetivo de variância com a utilização do critério empírico para obtenção do parâmetro de suavização polinomial. O uso da função objetivo de coeficiente de determinação ainda requer uma etapa aperfeiçoamento do modelo antes de ser possível uma aplicação de forma automatizada.

Tabela 4.1: Modelos de Planta para o estudo de Caso 4.4.

Planta	FT
A	$\frac{8\exp(-5s)}{(15s + 1)}$
B	$\frac{30\exp(-15s)}{(70s + 1)}$
C	$\frac{2(3s + 1)\exp(-5s)}{(4s + 1)(6s + 1)}$
D	$\frac{40(3s + 1)\exp(-20s)}{(20s + 1)(30s + 1)}$
E	$\frac{(-3s + 1)\exp(-2s)}{(7s + 1)(8s + 1)}$
F	$\frac{(-6s + 1)\exp(-7s)}{(4s + 1)(6s + 1)}$
G	$\frac{2\exp(-2s)}{(4s + 1)(6s + 1)}$
H	$\frac{2\exp(-6s)}{(25s^2 + 5s + 1)}$

Este estudo de caso é composto por 10 diferentes distúrbios não medidos, que podem ser visualizados na Figura 4.45. Para representá-los foram utilizados dois sinais periódicos do tipo PRBS, dois sinais do tipo senoidal, quatro sinais ruído branco, coloridos através de funções de transferência de primeira ordem, e dois sinais randômicos interpolados pela função *Spline*.

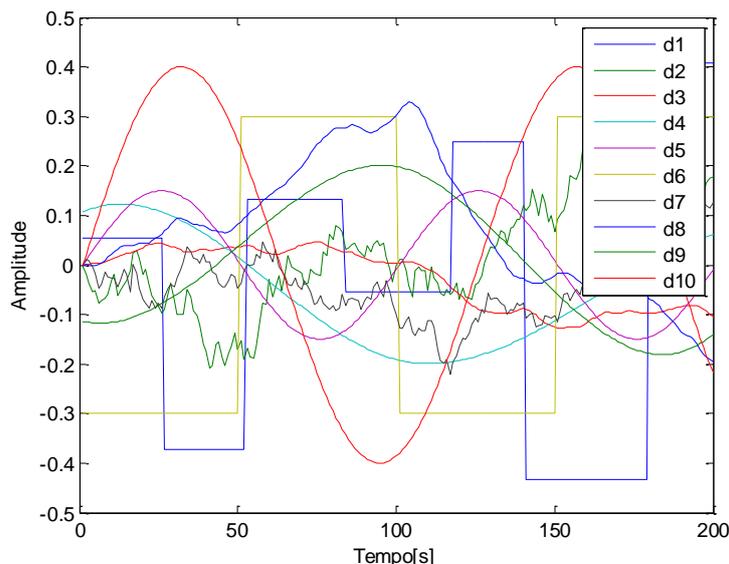


Figura 4.45: Sinais utilizados para representar os diferentes distúrbios não medidos utilizados nas simulações.

Os ajustes dos controladores foram escolhidos de forma randômica com ganho proporcional entre 0 e 10, com constante de tempo integral entre 0 e 50 e com constante de tempo derivativa entre 0 e 2. Contudo, de forma a manter aproximadamente todas as variáveis controladas estáveis, houve a necessidade de restringir os parâmetros dos controladores de forma a manter o critério de robustez, máxima sensibilidade (Astrom & Hägglund 1995), entre 1.2 e 1.6. Desta forma, verifica-se que, mesmo os ajustes sendo randômicos, os valores de ganho proporcional selecionados pelo algoritmo não excederam 2, de forma a manter a estabilidade do sistema.

O ruído de medição é um sinal randômico branco. Foram consideradas duas situações distintas, uma com ruído de medição SNR 5% e outra com ruído de medição SNR 30%. Sendo assim, a combinação das 8 plantas, com 4 ajustes, com 10 distúrbios e com SNR 5% e 30% resultou em 640 casos. A seguir alguns resultados serão discutidos e apresentados. A listagem completa dos tempos mortos obtidos pode ser encontrada no Apêndice A.

Na Tabela 4.2 podem ser visualizados os resultados da estimação do tempo morto para a Planta B e SNR 5%, onde os valores marcados em azul podem ser considerados como boas estimativas para o tempo morto.

Tabela 4.2: Resultados da estimação do θ para Planta B com SNR 5%--Tempo Morto verdadeiro é de 15s.

Planta B SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	6,5	7,5	12,0	13,4	15,0	10,5	10,4	12,3	15,0	4,4
Ajuste 2	6,5	7,5	12,6	14,6	15,1	14,6	10,4	15,0	3,5	0,0
Ajuste 3	7,5	7,5	11,8	15,0	14,9	14,5	10,5	15,0	14,8	1,4
Ajuste 4	6,5	7,6	12,3	15,0	18,2	14,5	9,6	11,4	14,6	14,8

A partir dos resultados da Tabela 4.2 verifica-se boa capacidade de estimar o tempo morto de forma não intrusiva, pois em aproximadamente 70% dos resultados o tempo morto estimado desviou no máximo cinco unidades do correto. Os principais desvios estão associados aos distúrbios d1, d2 e d10. Estima-se que isto tenha ocorrido porque o parâmetro de suavização não foi o adequado para estas situações. Estes resultados mostram que a metodologia independe do ajuste utilizado, uma vez que a maioria de incidência de resultados falhos não esta associada ao ajuste do controlador.

Com SNR 5% e para SNR 30% a metodologia proposta obteve de precisão similar. Sendo assim, conclui-se que o impacto ruído medição não foi significativo e o método não é fortemente dependente de pré-tratamento dos dados para valores de ruído de medição abaixo de 30%.

Em virtude das plantas estudadas possuem grande diferença estrutural (ordem, existência de zeros ou não), verifica-se que os resultados podem variar muito de um caso para outro, dificultando a avaliação dos resultados de maneira geral. Em casos onde o modelo inicial IMC não conseguia prever a parametrização correta da planta houve uma redução na eficácia do método. É importante mencionar que este estudo não levou em conta a função objetivo de coeficiente de determinação nem da etapa de atualização do modelo, em virtude dos problemas de automatização da técnica previamente discutidos. Dessa forma, estima-se que os resultados tendem a melhorar consideravelmente quando a abordagem combinada foi levada em conta.

Mesmo nos casos onde havia zeros positivos ou negativos na planta, que não eram previstos pelo modelo inicial, foi possível obter uma resposta próxima do tempo morto verdadeiro. Contudo, nota-se que o valor estimado tende a se deslocar em relação ao valor real devido à influência dos zeros do sistema. Este efeito pode ser visualizado na Tabela 4.3, com os resultados da estimação do tempo morto para a Planta C e SNR 5%, onde os valores marcados em azul representam um desvio máximo de 2.2s em relação ao valor original da planta, que é de 5s.

Tabela 4.3: Resultados da estimação do θ para Planta C com SNR 5%--Tempo Morto verdadeiro é de 5s.

Planta C SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	3.7	1.7	3.5	13.0	0.91	1.9	9.1	1.9	1.8	1.9
Ajuste 2	3.6	2.2	12.0	1.2	1.40	0.0	2.3	1.8	2.2	1.8
Ajuste 3	1.8	2.1	2.2	0.0	4.10	2.8	2.7	9.4	1.8	1.9
Ajuste 4	1.8	1.9	3.5	14.0	14.00	3.2	2.3	3.3	14.0	2.2

A partir da visualização dos resultados da Tabela 4.3 nota-se que os principais desvios estão associados aos distúrbios d4 e d5. Novamente pela escolha inadequada do parâmetro de suavização. Diante dos resultados da Tabela 4.3 e Tabela 4.2 é possível visualizar que o tipo de distúrbio impacta na qualidade da estimativa. Isto ocorre justamente pela dependência do parâmetro de suavização, que está atrelado ao formato do distúrbio.

As Figuras 4.46, 4.47 e 4.48 apresentam, respectivamente, o comportamento da função objetivo de variância com a variável de decisão tempo morto para a planta A, para a planta J e para a planta C. Com a visualização destas curvas é possível perceber a formação de um mínimo global próximo do tempo morto correto do sistema.

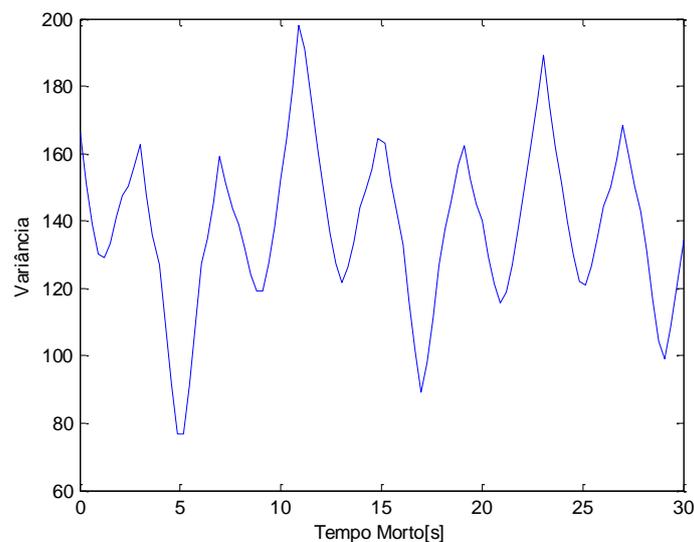


Figura 4.46: Comportamento da função objetivo de variância para planta A, distúrbio d1 e ajuste 1.

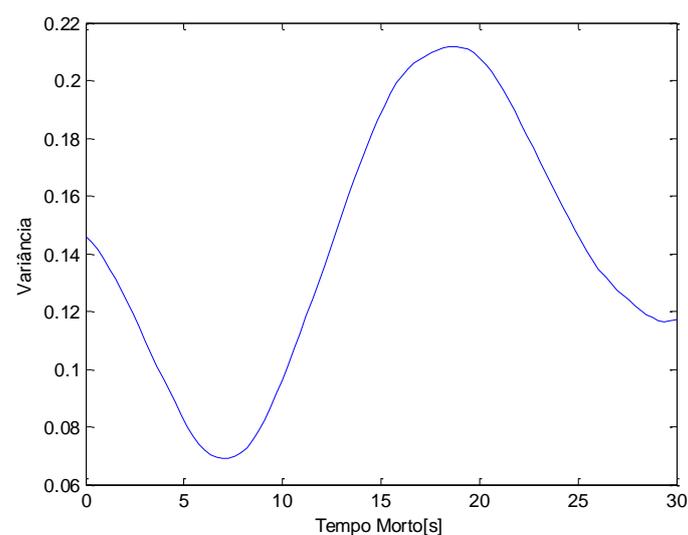


Figura 4.47: Comportamento da função objetivo de variância para planta H, distúrbio d5 e ajuste 3.

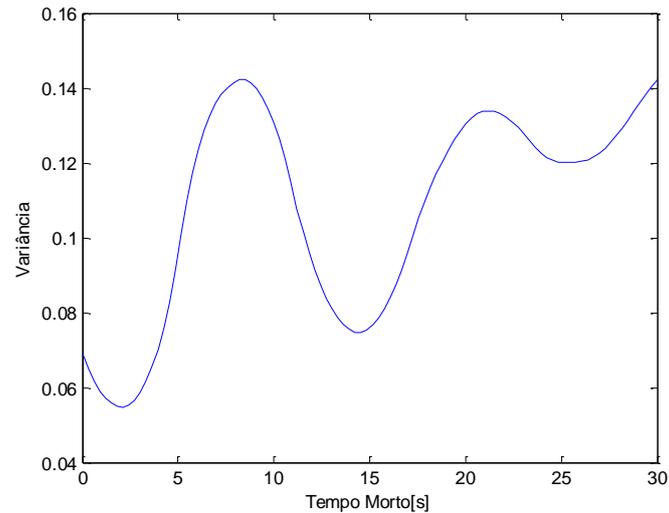


Figura 4.48: Comportamento da função objetivo de variância para planta C, distúrbio d9 e ajuste 2.

Como pode ser observado no Apêndice A, a estimação do tempo morto da planta D falhou. Isso se deve principalmente pelo valor do parâmetro de suavização não ser adequado. A metodologia, sem o uso da função objetivo de coeficiente de determinação, tende a selecionar parâmetros de suavização elevados. Verifica-se que esta planta, em particular, requeria o uso de parâmetros de suavização mais baixos para estimar o tempo morto corretamente. A ideia é fazer uso da função objetivo de coeficiente de determinação para contornar a necessidade de informar o parâmetro de suavização.

Nas Figura 4.49 e Figura 4.50, segue o comportamento das funções objetivo de coeficiente de determinação para modelos de segunda ordem, para a planta D com distúrbio d10 e ajuste 2. É possível verificar, que com o uso da função objetivo de coeficiente de determinação, há forte tendência de formação de mínimo global próximo do tempo morto verdadeiro do sistema. Possivelmente, com uma pequena alteração do modelo a presença do mínimo global se tornaria mais evidente. Além disso, a função objetivo de variância foi capaz de obter o resultado correto para parâmetros de suavização baixos.

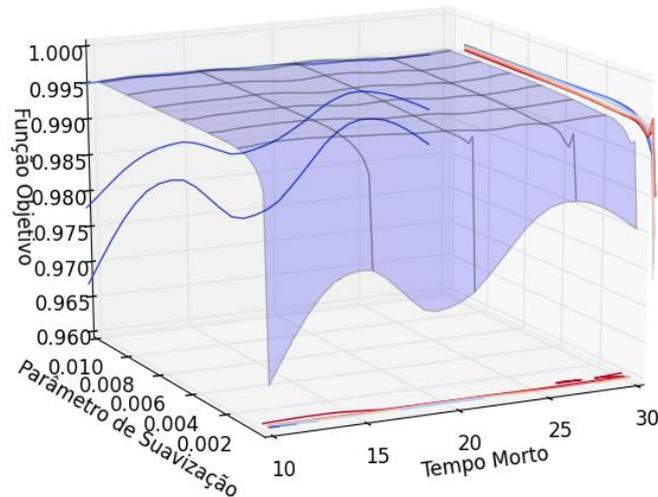


Figura 4.49: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto.

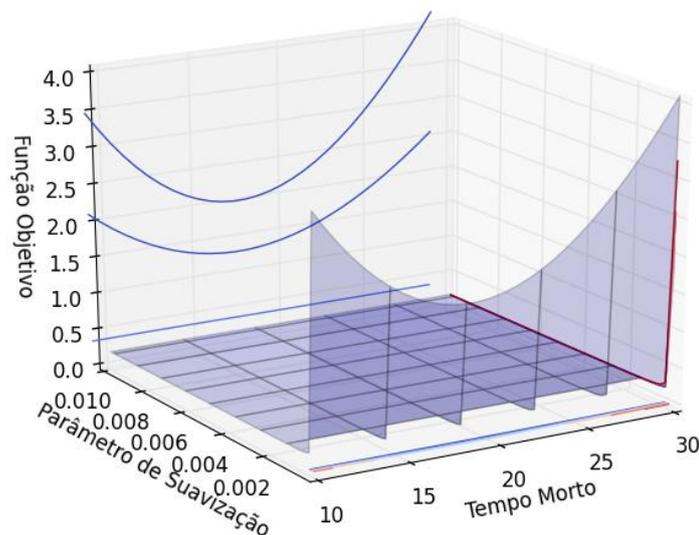


Figura 4.50: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto.

O valor da razão sinal ruído, com suavização 0.00001, foi aproximadamente 7.6. Verifica-se que uma redução no ganho do modelo de 240 para 10 reduziu a razão sinal ruído para 6 reduzindo a sensibilidade da função objetivo. Contudo, uma modificação na constante de tempo do modelo de 24 para 0.1 se mostrou benéfica para o formato da curva e reduziu a razão sinal ruído para 3.

Ainda, para este caso foi necessário o uso de modelos de segunda ordem, pois com modelos de primeira, a função objetivo se mostrou sem sensibilidade. Isso mostra que há forte dependência no modelo utilizado, de forma que seria necessário o conhecimento da ordem do sistema (primeira ou segunda). Isto pode ser contornado com a utilização de alguma metodologia capaz de estimar a ordem da planta. Ou até mesmo com alterações no modelo de primeira ordem, visando compensar esta necessidade.

4.5 Comparação com outros Métodos

A fim de avaliar a qualidade da metodologia proposta frente a outros trabalhos da literatura foi considerado um sistema SISO em malha fechada com a seguinte função de transferência representando a planta:

$$\frac{4e^{-5s}}{4s+1} \quad (4.9)$$

O distúrbio não medido inserido no sistema pode ser visualizado na Figura 4.51 é um ruído branco colorido através de uma função de transferência de primeira ordem com ganho 24 e constante de tempo 550.

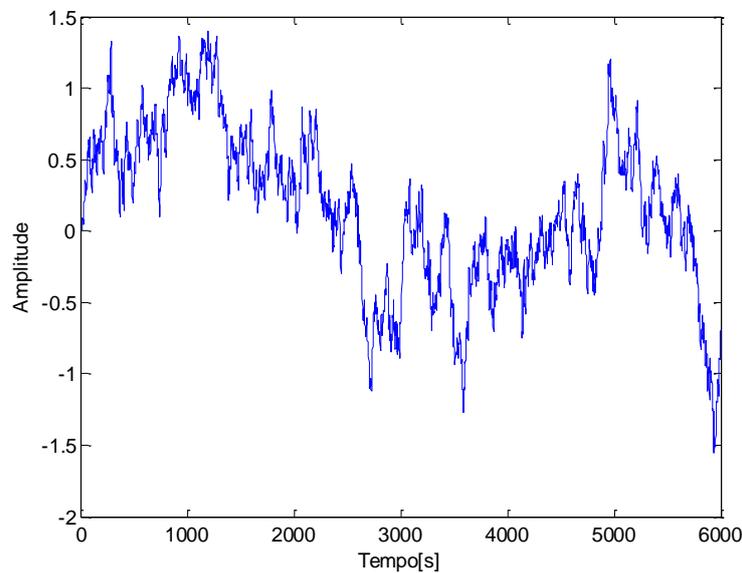


Figura 4.51: Sinal que representa o distúrbio não medido.

O tempo de simulação foi de 6000 segundos com tempo de amostragem de 1 segundo. O controlador utilizado foi um PI com ganho proporcional de 0.225 e constante de tempo integral de 10. Note que este estudo de caso é parecido com o encontrado no trabalho de Harrison e Qin (2012). O ruído de medição é um sinal randômico branco com intensidade SNR 15%.

Na metodologia proposta por este trabalho não há necessidade de qualquer mudança de *setpoint* ou testes intrusivos na planta, de modo que dados históricos de processo já são suficiente para análise. Contudo, em todas metodologias presentes na literatura existe a necessidade de testes intrusivos na planta. Por exemplo, a metodologia clássica baseada em ARX (Ljung 1987) necessita de dados com mudança de *setpoint*. Já a metodologia de Harrison and Qin (2012) há necessidade de alteração no ganho proporcional do controlador. Sendo assim, de forma a comparar a qualidade das três metodologias citadas em situações similares, foram gerados dados de simulação no *Matlab* com as respectivas limitações de cada método descrito. Na Figura 4.52 é possível comparar a variável controlada y ao longo do tempo de simulação para os três subcasos.

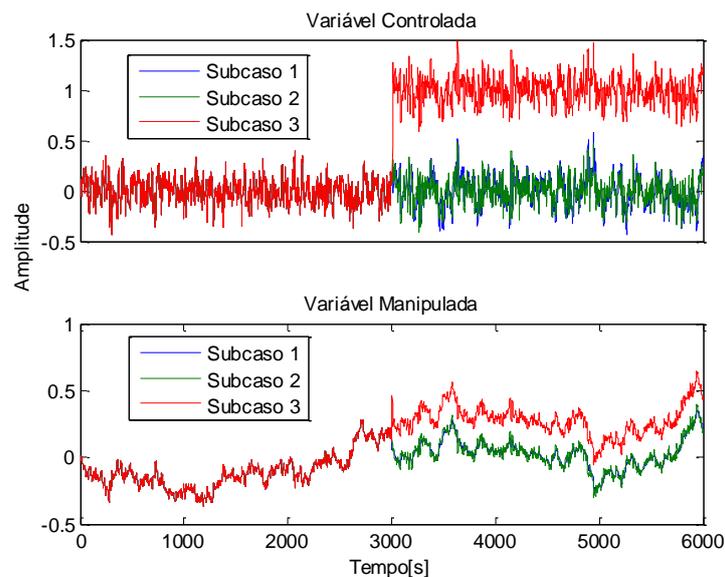


Figura 4.52: Variável controlada e variável manipulada para os três subcasos.

O subcaso 1 apresenta redução no ganho proporcional do controlador de 0.225 para 0.1125 a partir de 3000 segundos. O subcaso 2 não apresenta qualquer tipo de modificação na planta, contendo apenas influência do distúrbio não medido. O subcaso 3 apresenta mudança de *setpoint* de 0 para 1.

Em virtude do método proposto pelo presente trabalho não necessitar de um grande volume de dados foi possível fragmentar a janela de 6000 pontos em janelas menores e aplicar a metodologia em formato de janela móvel. Sendo assim, a metodologia foi aplicada em cada uma das 50 janelas, cada uma com 500 pontos, resultando em um tempo morto médio. Na Figura 4.53 é possível visualizar uma das funções objetivo, gerada ao longo do procedimento descrito.

Na Tabela 4.4 se encontram os resultados da aplicação das 3 metodologias para os 3 subcasos de dados apresentados.

Tabela 4.4: Resultado da aplicação das 3 metodologias para os 3 subcasos de dados apresentados no estudo de caso 4.5.

Método	Subcaso 1	Subcaso 2	Subcaso 3
Harrison and Qin	6.0	-	-
Método Proposto	7.0	6.0	5.9
ARX	1.0	30.0	5.0

Os resultados da Tabela 4.4 foram obtidos com a aplicação da função objetivo de variância com o critério heurístico de seleção do parâmetro de suavização. A partir dos resultados da Tabela 4.4 é possível verificar que a metodologia se mostrou eficaz em estimar o tempo morto do sistema de forma não intrusiva em situações que os outros métodos não foram.

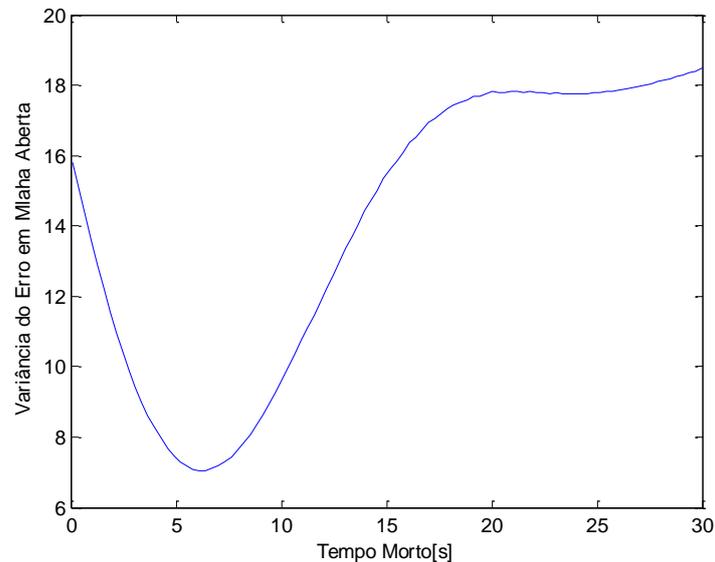


Figura 4.53: Função objetivo de variância versus tempo morto para uma das janelas móveis.

A fim de verificar o comportamento da função objetivo de coeficiente de determinação, a metodologia descrita pelo fluxograma foi aplicada apenas nos dados gerados pelo subcaso 2. O modelo inicial pode ser representado pela função de transferência abaixo:

$$\frac{4.4}{10s+1} \quad (4.10)$$

O tamanho da janela foi definido, a partir do critério da frequência em que o tempo morto afeta o EMA, como sendo aproximadamente 200 segundos. A Figura 4.54 mostra o comportamento do EMA em todo o intervalo da simulação para o modelo inicial e a Figura 4.55 mostra o comportamento para a janela escolhida para aplicar a metodologia.

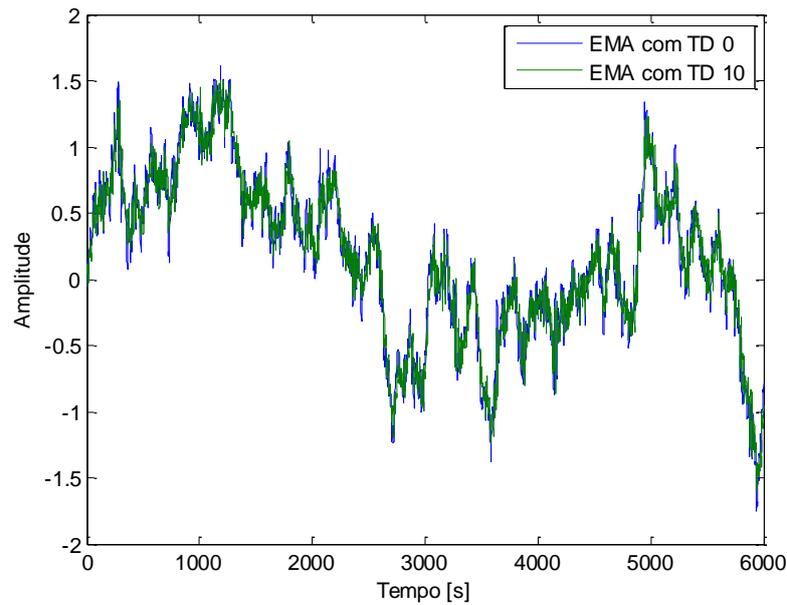


Figura 4.54: Comportamento do EMA em todo intervalo de simulação para o modelo inicial para diferentes tempos mortos.

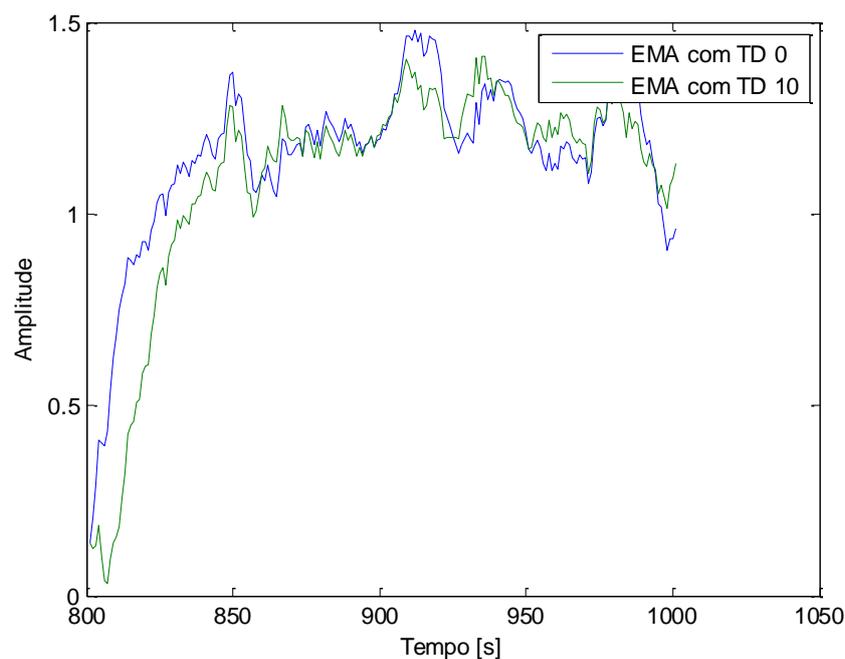


Figura 4.55: Comportamento do EMA na janela de aplicação da metodologia para o modelo inicial para diferentes tempos mortos.

Nas Figura 4.56 e Figura 4.57 podem ser visualizadas as funções objetivo de coeficiente de determinação e variância para o modelo inicial, respectivamente. Verifica-se um mínimo global próximo do tempo morto correto do sistema (5s) na função objetivo de coeficiente de determinação. A função objetivo de variância apresenta um mínimo global próximo do valor correto para parâmetros e suavização muito baixos (próximo a 0.02). Verifica-se que para valores de suavização maiores o resultado tenderia para aproximadamente dois.

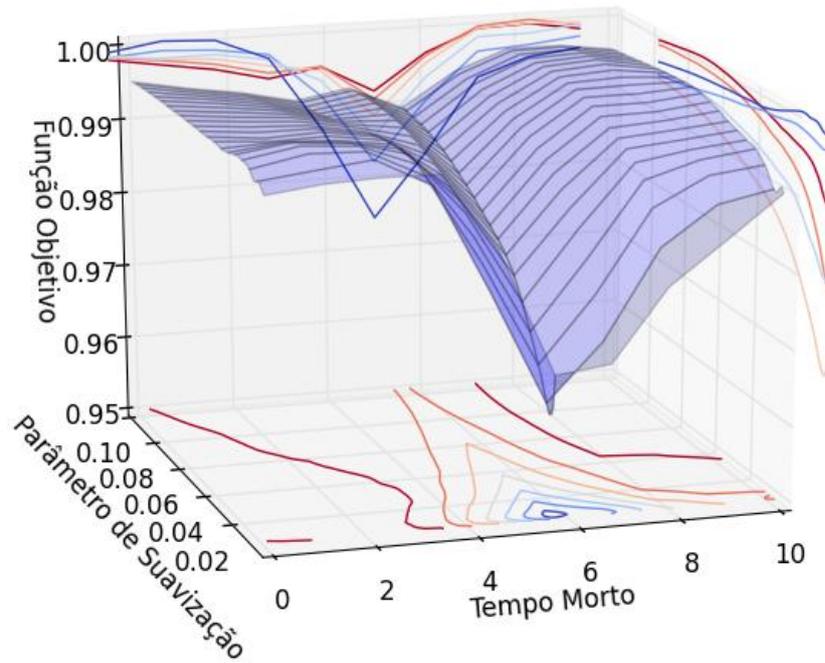


Figura 4.56: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo inicial.

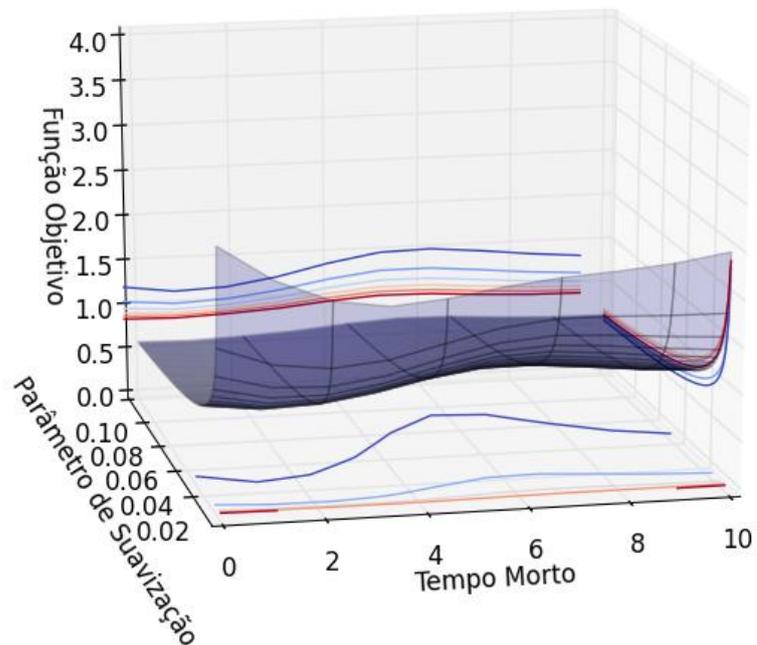


Figura 4.57: Comportamento da função objetivo de variância versus parâmetro de suavização e tempo morto para o modelo inicial.

A Figura 4.58 mostra o comportamento do EMA e da *spline* suavizante para o parâmetro de suavização 0.001 e para o tempo morto correto.

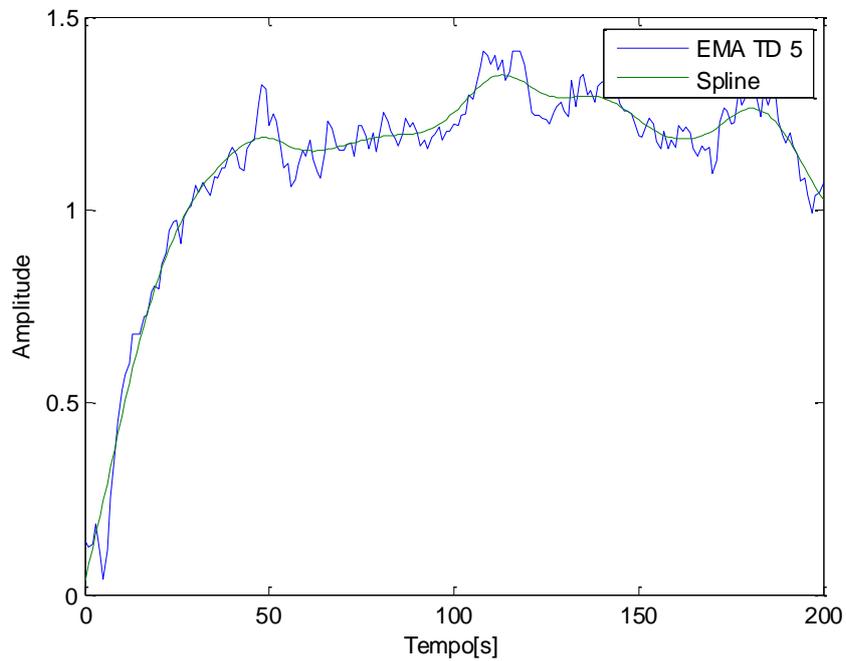


Figura 4.58: Comportamento do EMA e da *spline* suavizante próximo do mínimo global da função objetivo.

Com uma pequena alteração no ganho do modelo para 1.7 é possível melhorar o formato da superfície. A Figura 4.59 mostra o comportamento do EMA e Figura 4.60 mostra o comportamento da função objetivo de coeficiente de determinação após alteração do modelo inicial.

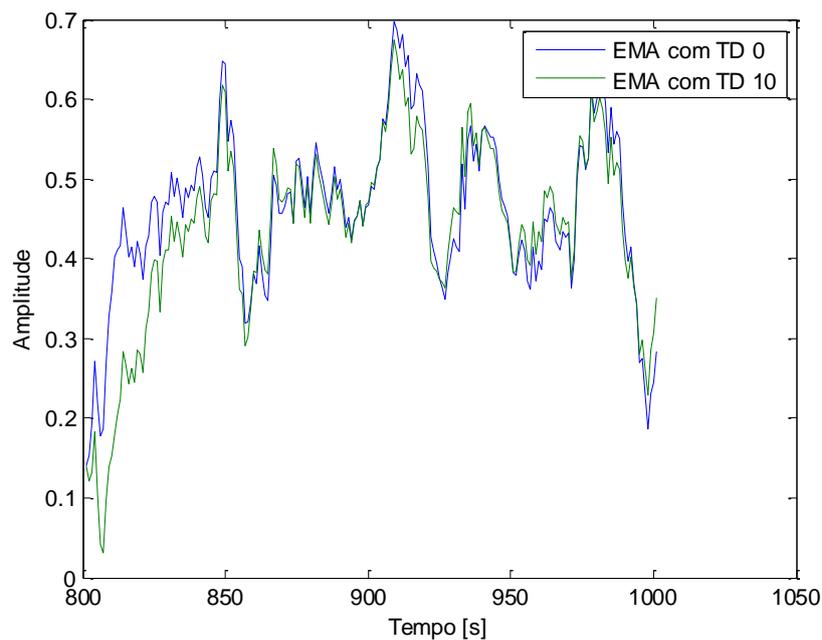


Figura 4.59: Comportamento do EMA na janela de aplicação da metodologia para o modelo para diferentes tempos mortos.

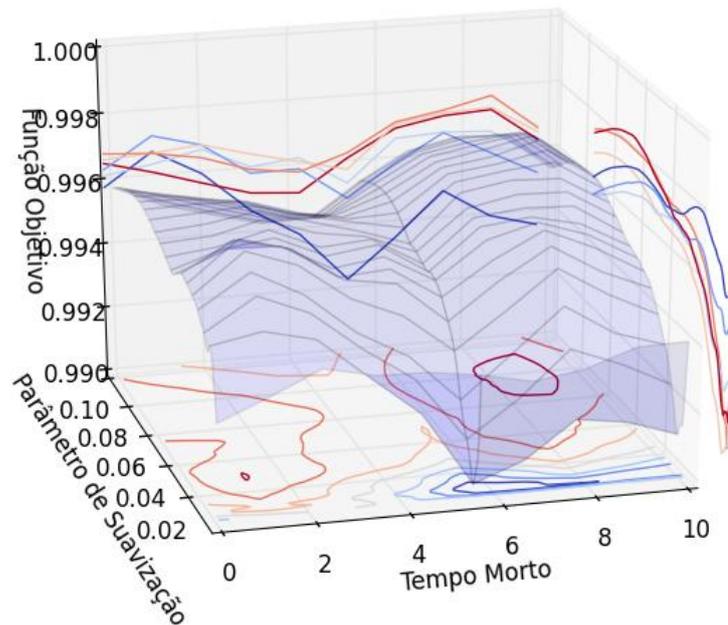


Figura 4.60: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto para o modelo.

Conforme esperado, é possível obter uma melhora significativa no formato da função objetivo a partir de alterações no modelo base. Contudo, vale ressaltar que para este estudo de caso em particular, não foi necessário esta alteração, ou seja, o modelo inicial já era adequado para obtenção de um resultado satisfatório na estimação.

Este estudo de caso mostra que a metodologia proposta é capaz de estimar o tempo de forma não intrusiva em situações que as metodologias clássicas falhariam na estimativa. Este aspecto é particularmente vantajoso em casos que a malha de controle em questão seja sensível a perturbações tipo degrau, uma vez que, segundo a metodologia ARX descrita por Ljung (1987), o tamanho do degrau unitário aplicado ao sistema deve ser suficientemente grande para ser possível estimar os parâmetros do modelo.

Além disto, o método proposto pode ser aplicado continuamente de forma a monitorar o desempenho dos sistemas, sem a necessidade de prejudicar a malha de controle com testes intrusivos. Aspecto importante, uma vez que industriais de grande porte possuem um grande número de malhas PID.

4.6 Tanque – Tempo morto variável

Com o objetivo de avaliar a metodologia proposta para fins de monitoramento de malhas de controle o presente estudo de caso simula situações em que o tempo morto do sistema possa ser alterado em virtude de distúrbios ou alteração da dinâmica do processo. Este estudo de caso toma como exemplo a situação descrita no capítulo 1, com um tanque em malha fechada com controlador C , que pode ser visualizada na Figura 4.61.

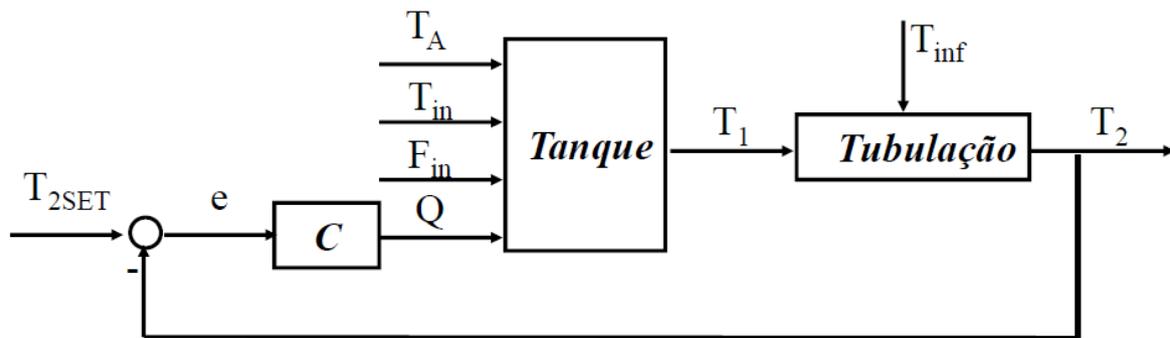


Figura 4.61: Diagrama de blocos do sistema em malha fechada.

O objetivo é controlar a temperatura de saída T_2 do tanque de volume V , através do calor Q do fluido de troca térmica. O fluido presente no tanque é água. O sistema está sujeito a um tempo morto θ associado ao comprimento da tubulação L , com área de seção transversal A . A partir de balanços é possível obter as funções de transferência que descrevem a planta e o distúrbio não medido na saída do processo, representados no diagrama de blocos da Figura 4.62.

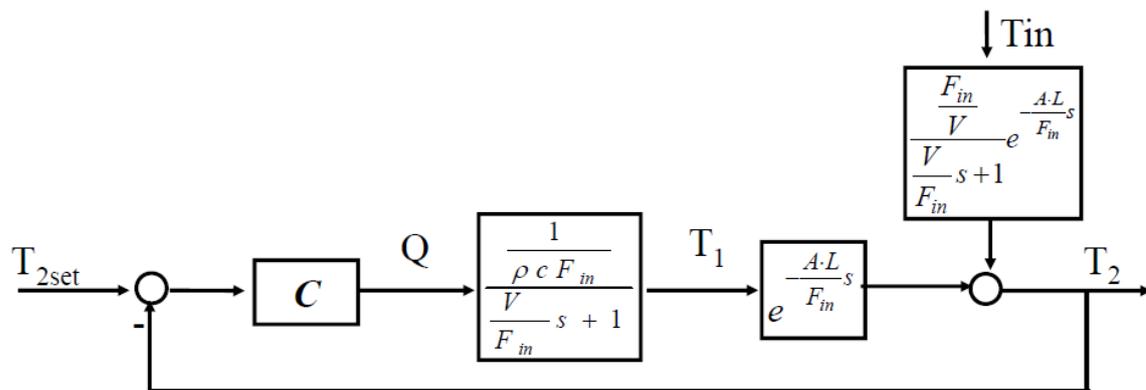


Figura 4.62: Diagrama de blocos com as funções de transferência que descrevem o processo.

O sistema está sujeito a dois distúrbios não medidos F_{in} e T_{in} . Devido à influência da modificação do valor de F_{in} ao longo da simulação, a função de transferência do tanque, do distúrbio não medido e o valor do tempo morto se modificam. O volume do tanque é de 2 m^3 , o comprimento da tubulação 20 m e a área da seção transversal 0.12 m^2 . O tempo de amostragem 1 segundo. O ganho do controlador é $100000 \text{ C}^\circ/\text{J}$, a constante de tempo integral 30 e a constante de tempo derivativa 0.01. O calor específico c da água foi considerado como $4180 \text{ J}/\text{KgC}^\circ$. A densidade da água ρ como $1000 \text{ Kg}/\text{m}^3$. O sinal referência T_{2set} foi considerado constante e igual a 10 C° ao longo da simulação de 6000 segundos. O ruído de medição foi aproximadamente SNR 5%. Para este estudo foram

considerados três valores de F_{in} : 0.24, 0.12 e 0.44 m^3/s , que podem ser visualizado na Figura 4.63. O tempo morto referente a cada valor de F_{in} foi 10, 20 e 5 segundos, respectivamente. Abaixo podem ser visualizadas as funções de transferência do tanque para cada valor de F_{in} , respectivamente.

$$\frac{9.97e-07}{8.33s+1} \quad (4.11)$$

$$\frac{1.99e-06}{16.7s+1} \quad (4.12)$$

$$\frac{5.44e-07}{4.54s+1} \quad (4.13)$$

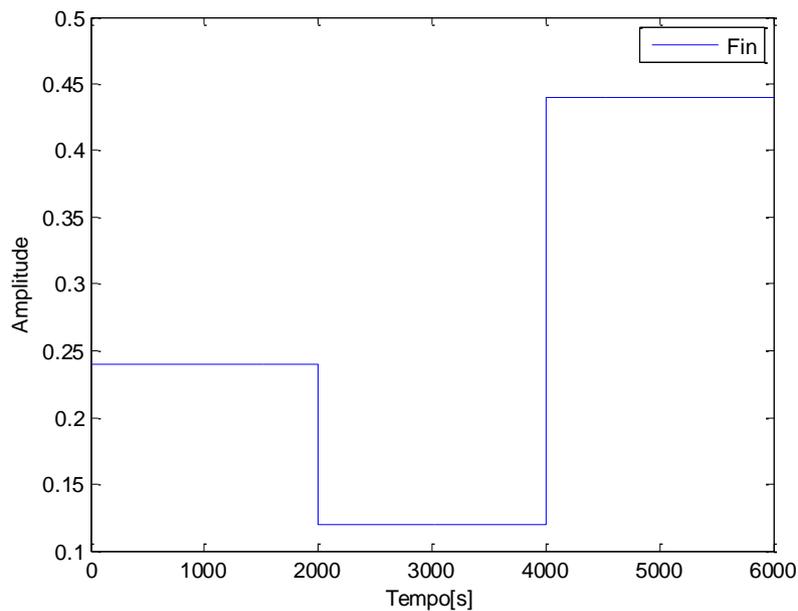


Figura 4.63: Sinal que representa o distúrbio não medido F_{in} ao longo da simulação.

Na Figura 4.64 pode ser visualizado o sinal de T_{in} e na Figura 4.65 o sinal do distúrbio não medido associado à modificação do valor de T_{in} . Na Figura 4.66 podem ser visualizadas a variável controlada e a variável manipulada.

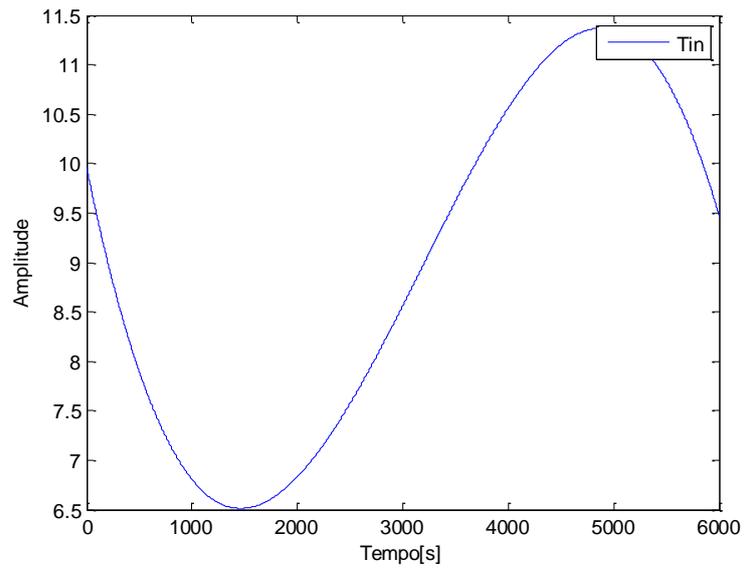


Figura 4.64: Sinal que representa T_{in} ao longo da simulação.

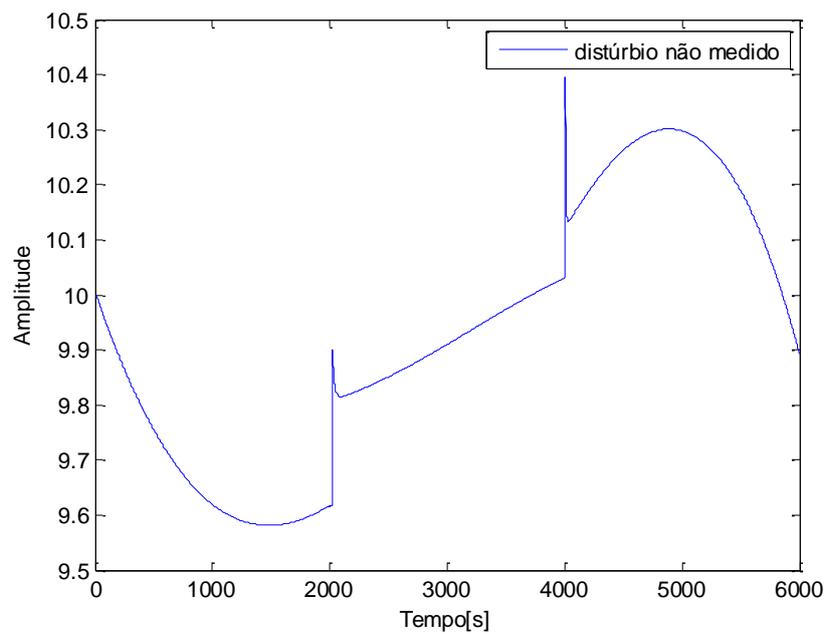


Figura 4.65: Sinal que representa o distúrbio não medido inserido na saída do processo.

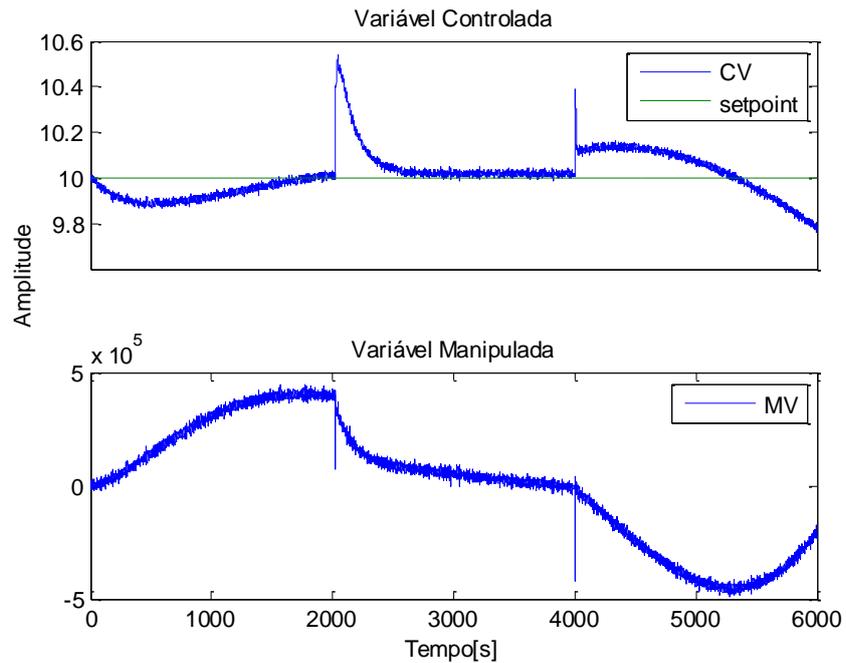


Figura 4.66: Variável controlada e variável manipulada para o estudo de caso 4.6.

Na Figura 4.67 pode ser visualizada a função objetivo de coeficiente de determinação para o modelo inicial. Verifica-se um mínimo global próximo do tempo morto correto do sistema (10s). A metodologia foi aplicada na janela de dados referente ao valor de 1 até 100 segundos.

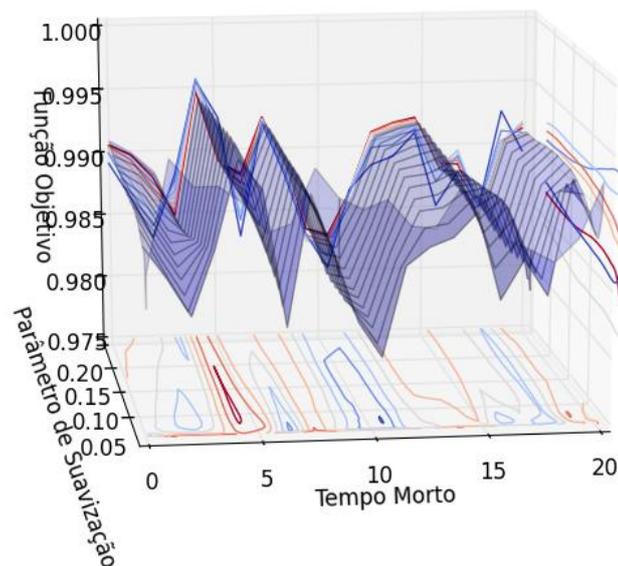


Figura 4.67: Comportamento da função objetivo de coeficiente de determinação para o estudo de caso 4.6.

Na Figura 4.68 pode ser visualizada a função objetivo de coeficiente de determinação para o modelo. Neste caso foi necessário um pequeno aumento no valor do ganho do modelo em relação ao inicial para melhorar a sensibilidade da função objetivo. Verifica-se um mínimo global próximo do tempo morto correto do sistema (20s). A metodologia foi aplicada na janela de dados referente ao valor de 3000 até 3150 segundos.

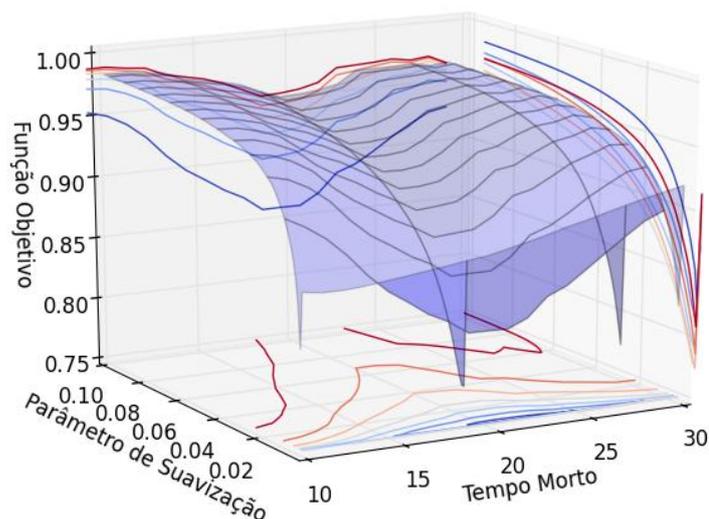


Figura 4.68: Comportamento da função objetivo de coeficiente de determinação para o estudo de caso 4.6.

Na Figura 4.69: pode ser visualizada a função objetivo de coeficiente de determinação para o modelo inicial. Verifica-se um mínimo global próximo do tempo morto correto do sistema (5s). A metodologia foi aplicada na janela de dados referente ao valor de 4500 até 4600 segundos.

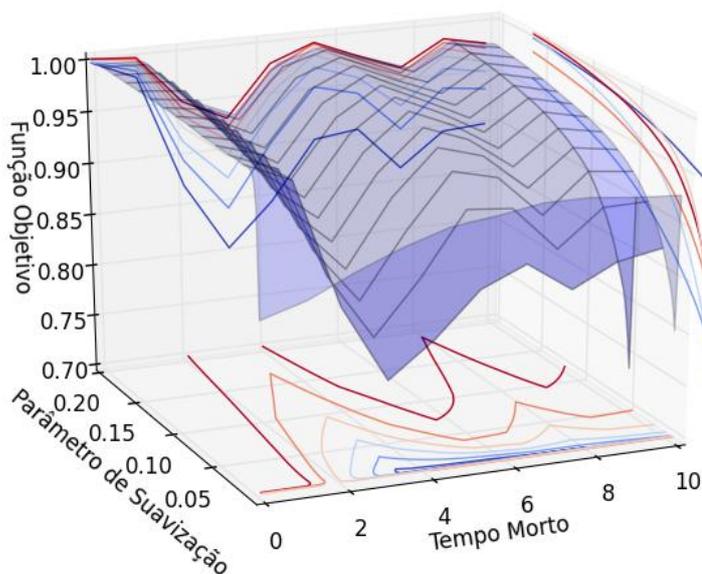


Figura 4.69: Comportamento da função objetivo de coeficiente de determinação para o estudo de caso 4.6.

Para aplicação da metodologia proposta foram considerados intervalos longe das modificações do valor de F_{in} , ou seja, onde havia pouca excitação no sistema. O que demonstra que a metodologia proposta é capaz de estimar de forma satisfatória o tempo morto do sistema de maneira não intrusiva. Este estudo de caso demonstra uma das diversas aplicações da estimativa *on-line* e não intrusiva do tempo morto, como por exemplo, a estimativa de distúrbios não medidos, neste caso o valor de F_{in} a partir da equação 1.1.

Capítulo 5 – Estudo de Casos – Aplicação Industrial

Este capítulo traz alguns exemplos de aplicação da metodologia proposta com dados de um processo real. Os dados foram coletados de malhas PID em uma refinaria e são apresentados após normalização. Desta forma o valor do tempo morto será calculado em intervalos de amostragem.

Foram estudadas duas malhas de nível e uma malha de temperatura. Tendo em vista que o tempo morto verdadeiro é desconhecido, foram selecionados conjuntos de dados com perturbações, de modo que a metodologia ARX pudesse ser aplicada e os tempos mortos calculados por ela e pela técnica proposta fossem comparados. A metodologia de identificação direta por ARX foi aplicada para três diferentes ordens de numerador e denominador, sendo elas 4, 10 e 20. Os resultados foram similares, desta forma conclui-se que o tempo morto obtido é uma boa estimativa do valor real.

5.1 Malha de Nível 1

A Figura 0.1 mostra a variável manipulada, controlada e o sinal de referência (*setpoint*).

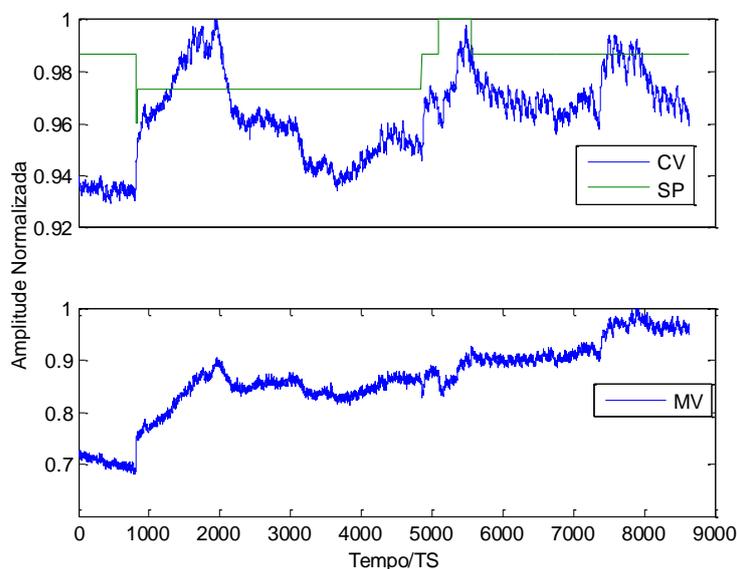


Figura 0.1: Variável manipulada, controlada e *setpoint* para o estudo de caso 5.1.

Uma estimativa do tempo morto real da planta pode ser obtida através da aplicação do método de identificação direta através de modelos ARX (Ljung 1987) em intervalos de janela com mudança no *setpoint*. A Figura 0.2 mostra o intervalo de tempo escolhido para aplicação da metodologia ARX. O tempo morto obtido através da identificação direta foi de 14 TS (tempos de amostragem). A Figura 0.3 mostra o intervalo de tempo utilizado para aplicação da metodologia proposta.

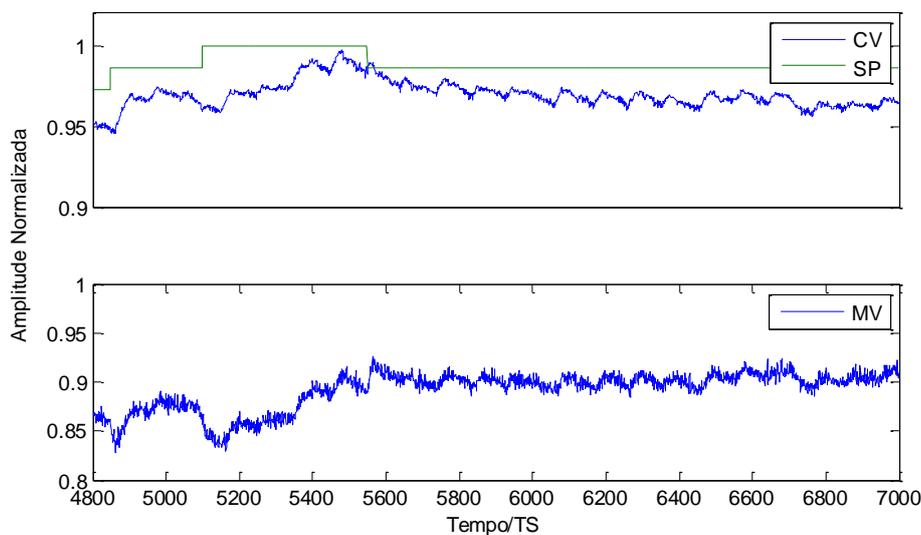


Figura 0.2: Intervalo de aplicação do método de identificação direta ARX.

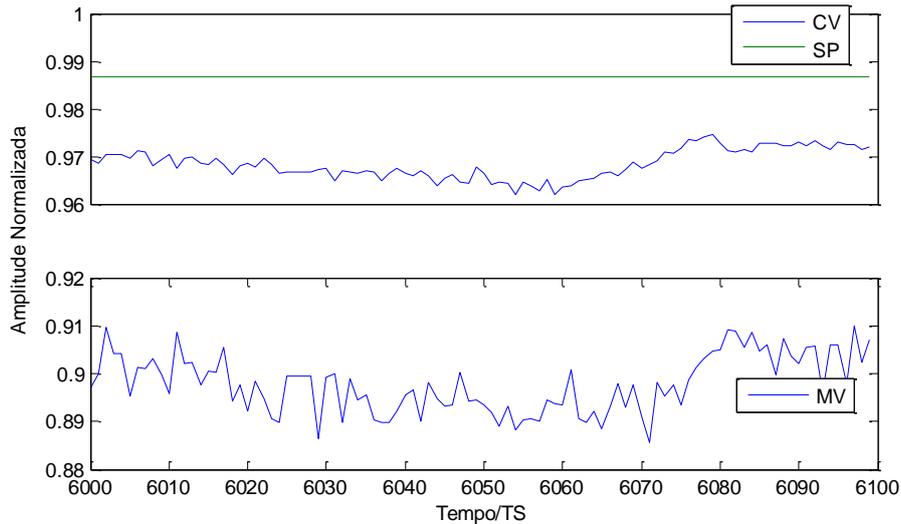


Figura 0.3: Intervalo de aplicação do método proposto.

A Figura 0.4 mostra uma ampliação da janela de 780 até 840, onde há a presença de uma mudança de *setpoint* mais intensa. A partir da simples visualização da figura é difícil obter uma estimativa do tempo morto, devido a forte influência de distúrbios não medidos no sistema. Isso destaca a importância da existência de uma metodologia não intrusiva para estimação do tempo morto.

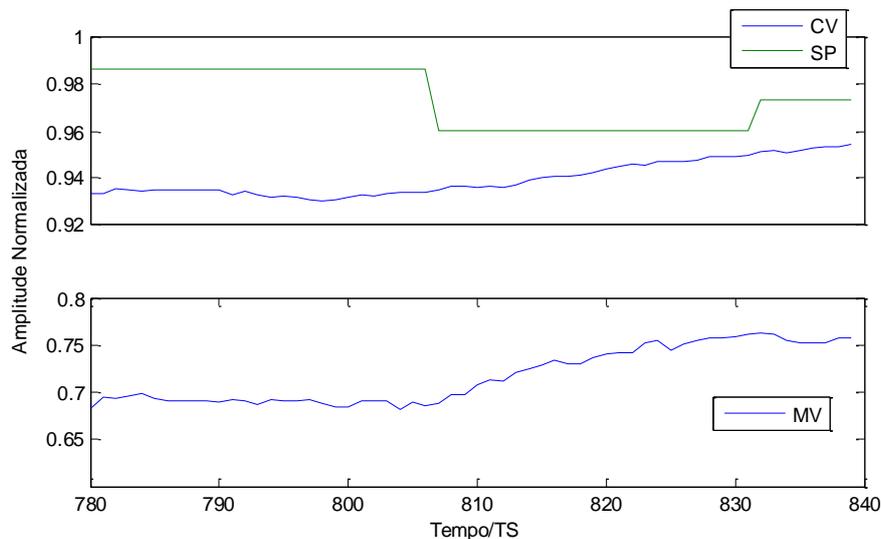


Figura 0.4: Ampliação da janela de mudança de *setpoint*.

A Figura 0.5 mostra a função objetivo de coeficiente de determinação com a utilização do modelo inicial. Há a formação de um mínimo local muito sutil próximo ao valor de 17 TS. Com uma modificação do modelo inicial foi possível modificar o formato da função objetivo como na Figura 0.6, que também apresenta mínimo local próximo a 17 TS.

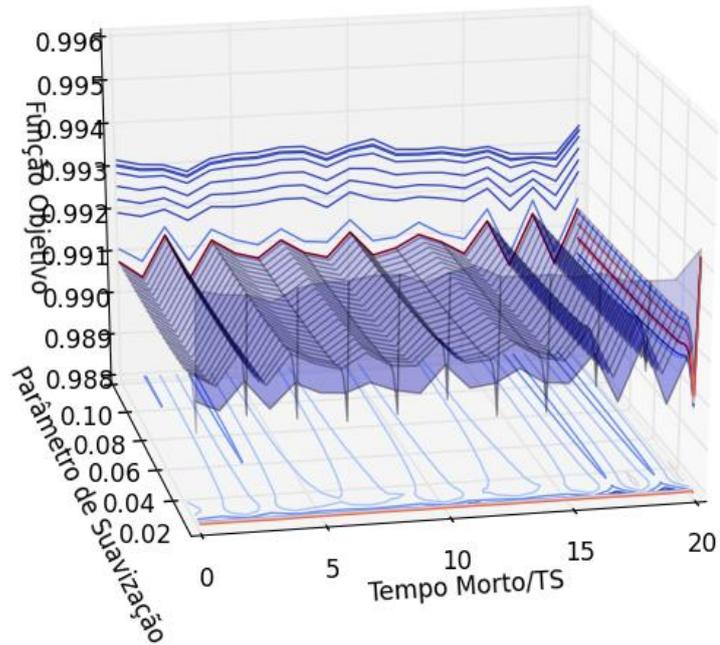


Figura 0.5: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo inicial.

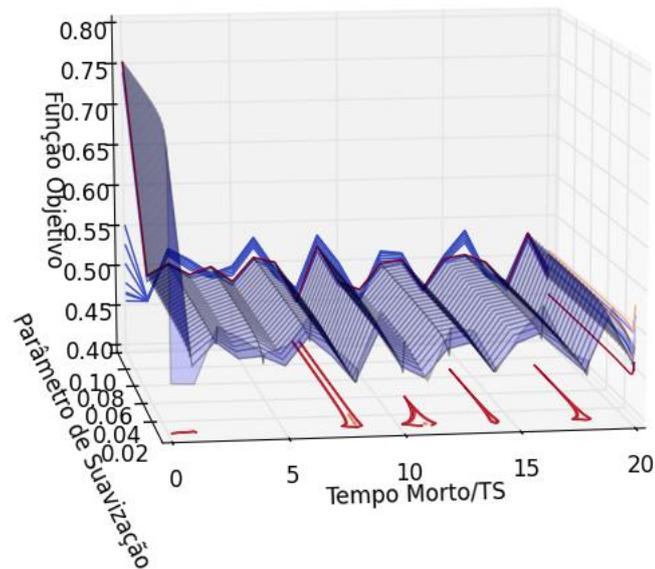


Figura 0.6: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo.

Apesar dos valores encontrados para o tempo morto serem aproximadamente compatíveis, a função objetivo da metodologia proposta se mostrou pouco sensível ao tempo morto. Isso pode ser aprimorado através de modificações no modelo.

5.2 Malha de Nível 2

A Figura 0.7 mostra a variável manipulada, controlada e o sinal de referência (*setpoint*).

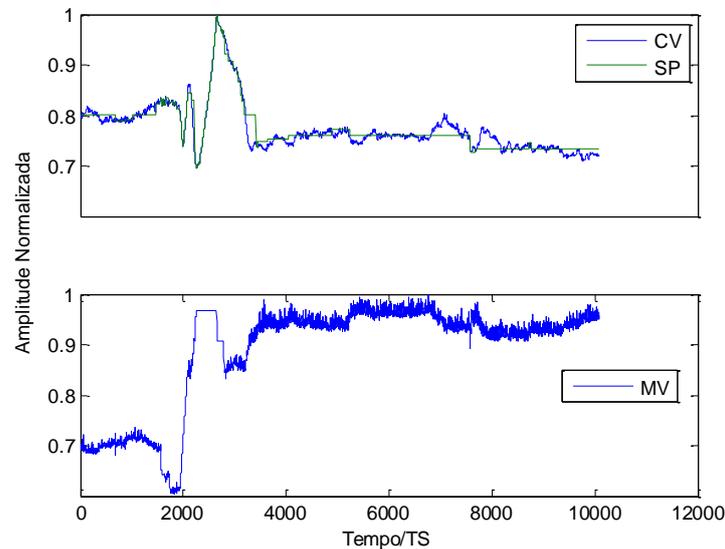


Figura 0.7: Variável manipulada, controlada e *setpoint* para o estudo de caso 5.2.

Uma estimativa do tempo morto real da planta pode ser obtida através da aplicação do método de identificação direta através de modelos ARX (Ljung 1987) em intervalos de janela com mudança no *setpoint*. A Figura 0.8 e Figura 0.9 mostram os intervalos de tempo escolhidos para aplicação da metodologia ARX. O tempo morto obtido através da identificação direta foi de 9 TS (tempos de amostragem) a primeira janela e 6 TS para a segunda. A Figura 0.10 mostra o intervalo de tempo utilizado para aplicação da metodologia proposta.

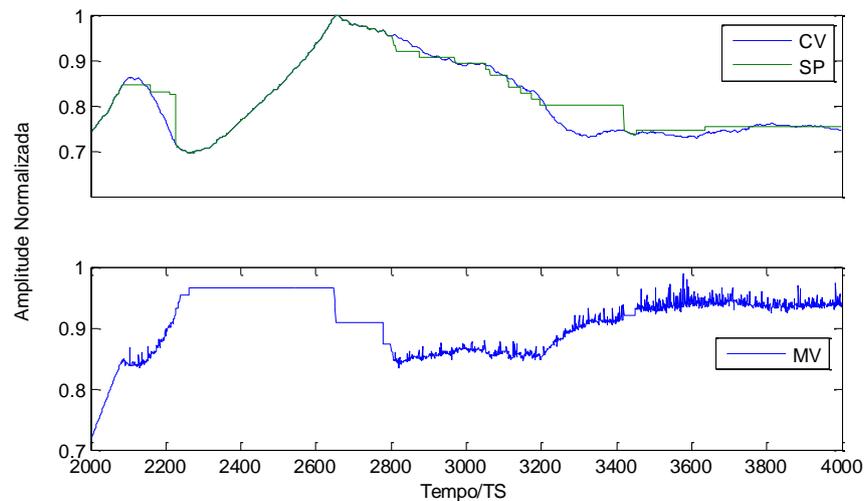


Figura 0.8: Intervalo de aplicação do método de identificação direta ARX: primeira janela.

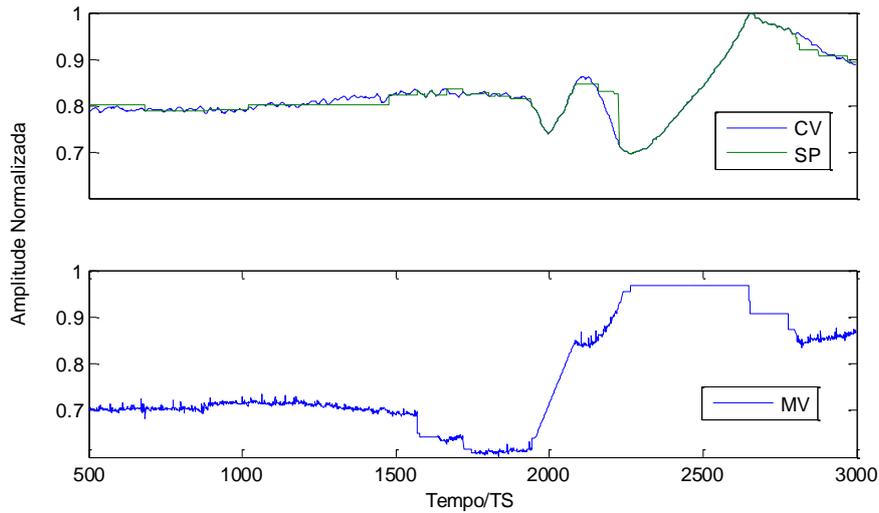


Figura 0.9: Intervalo de aplicação do método de identificação direta ARX: segunda janela.

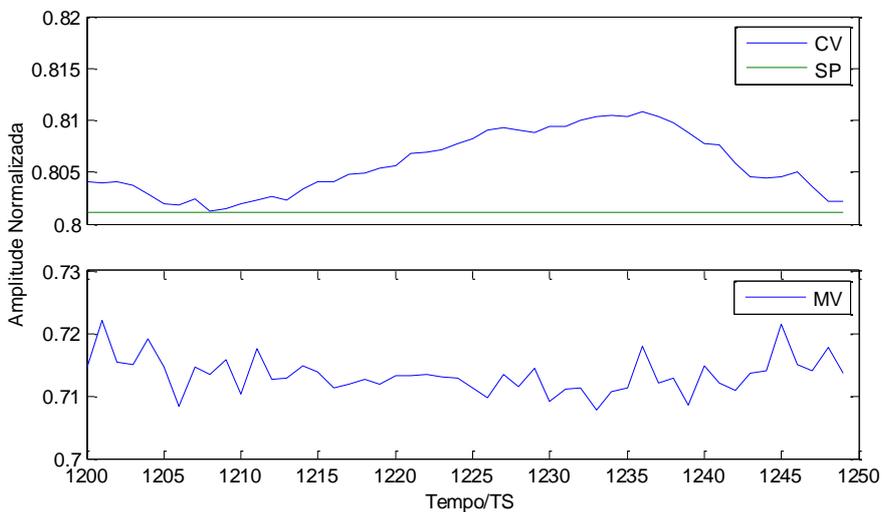


Figura 0.10: Intervalo de aplicação do método proposto.

A Figura 0.11 mostra uma ampliação da janela de 3160 até 3250, onde há a presença de uma mudança de *setpoint* mais intensa. Novamente, a partir da simples visualização da figura é difícil obter uma estimativa do tempo morto, devido a forte influência de distúrbios não medidos no sistema.

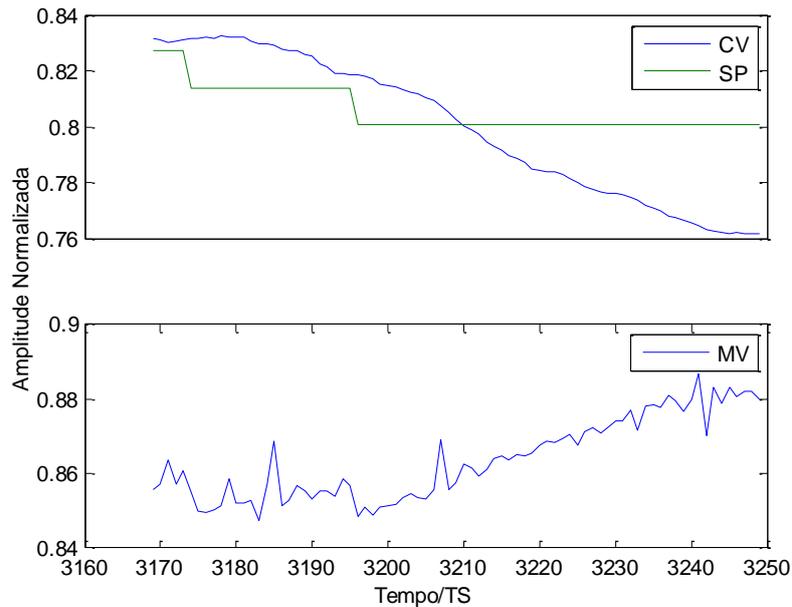


Figura 0.11: Ampliação da janela de mudança de *setpoint*.

A Figura 0.12 mostra a função objetivo de coeficiente de determinação com a utilização do modelo inicial. Há a formação de um mínimo global muito próximo ao valor de 9 TS. Com uma modificação do modelo inicial foi possível modificar o formato da função objetivo como na Figura 0.13, que também apresenta mínimo global próximo a 9 TS, mas com a formação de um mínimo local próximo a 6 TS, de maneira similar aos resultados do método ARX.

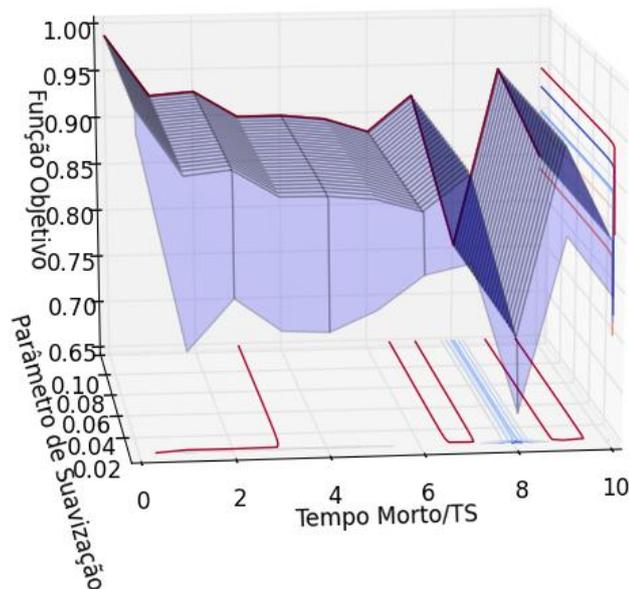


Figura 0.12: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo inicial.

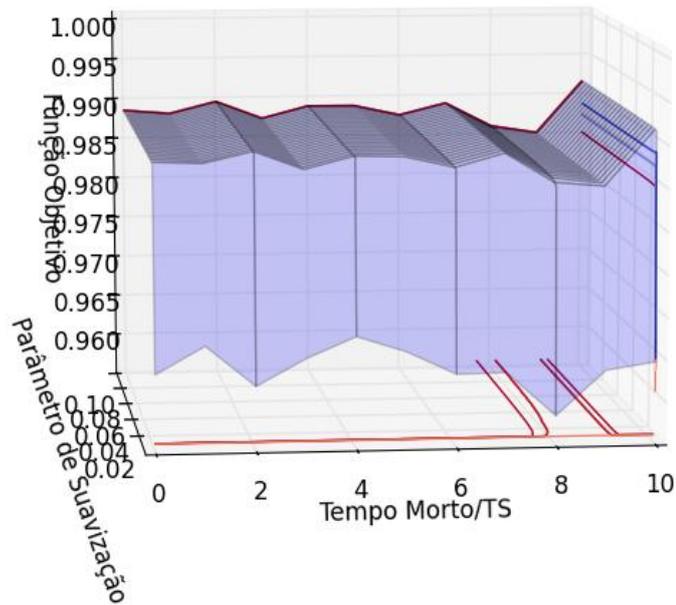


Figura 0.13: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo.

5.3 Malha de Temperatura

A Figura 0.14 mostra a variável manipulada, controlada e o sinal de referência (*setpoint*).

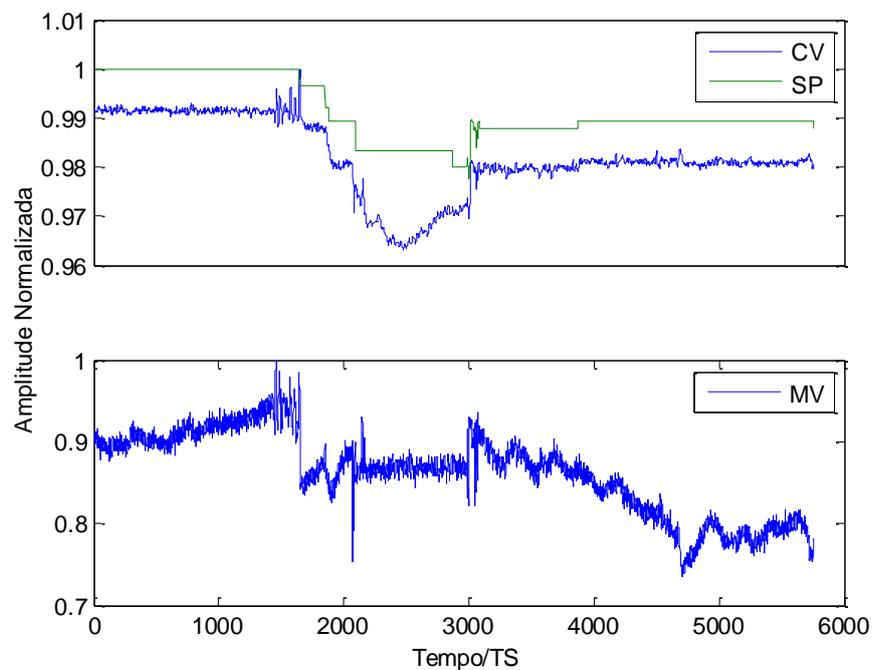


Figura 0.14: Variável manipulada, controlada e *setpoint* para o estudo de caso 5.3.

Uma estimativa do tempo morto real da planta pode ser obtida através da aplicação do método de identificação direta através de modelos ARX (Ljung 1987) em intervalos de janela com mudança no *setpoint*. A Figura 0.15 mostra o intervalo de tempo escolhido para aplicação da metodologia ARX. O tempo morto obtido através da identificação direta foi de 1 TS (tempos de amostragem). A Figura 0.16 mostra o intervalo de tempo utilizado para aplicação da metodologia proposta.

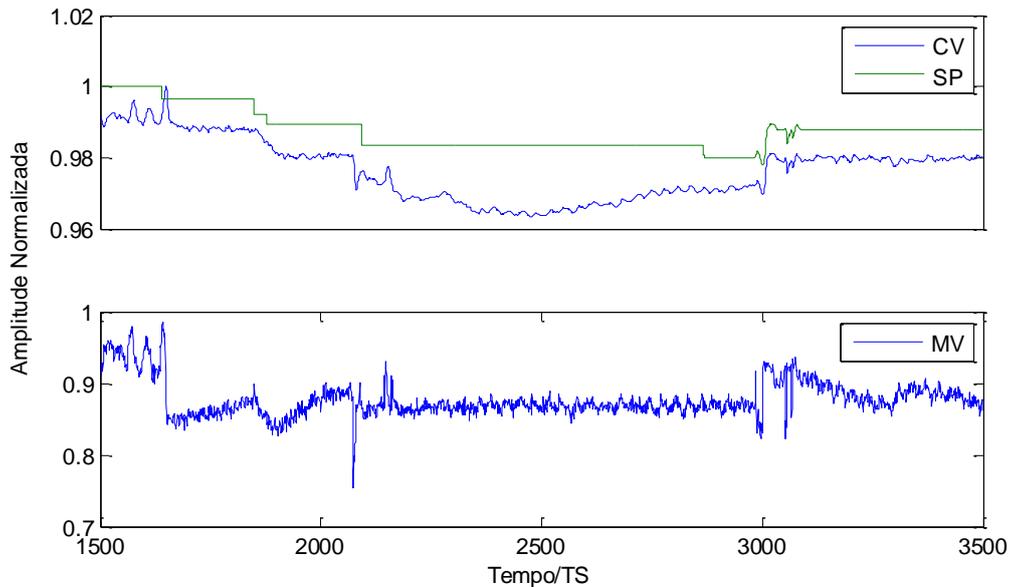


Figura 0.15: Intervalo de aplicação do método de identificação direta ARX.

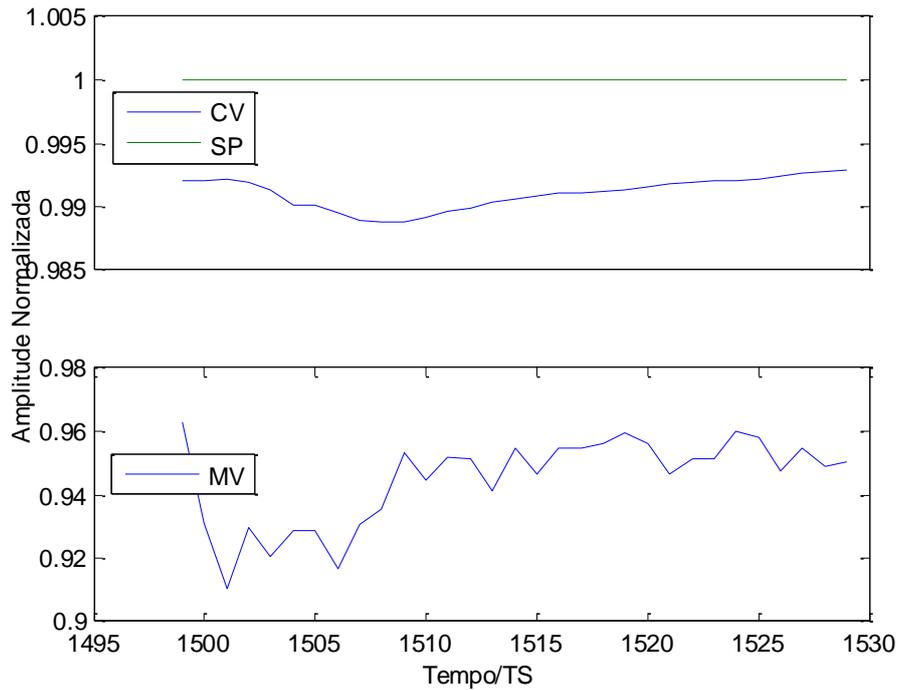


Figura 0.16: Intervalo de aplicação do método proposto.

A Figura 0.17 mostra a função objetivo de coeficiente de determinação com a utilização do modelo inicial. Há a formação de um mínimo global muito próximo ao valor de 1 TS. Com uma modificação do modelo inicial foi possível modificar o formato da função objetivo como na Figura 0.18, que também apresenta mínimo global próximo a 1 TS.

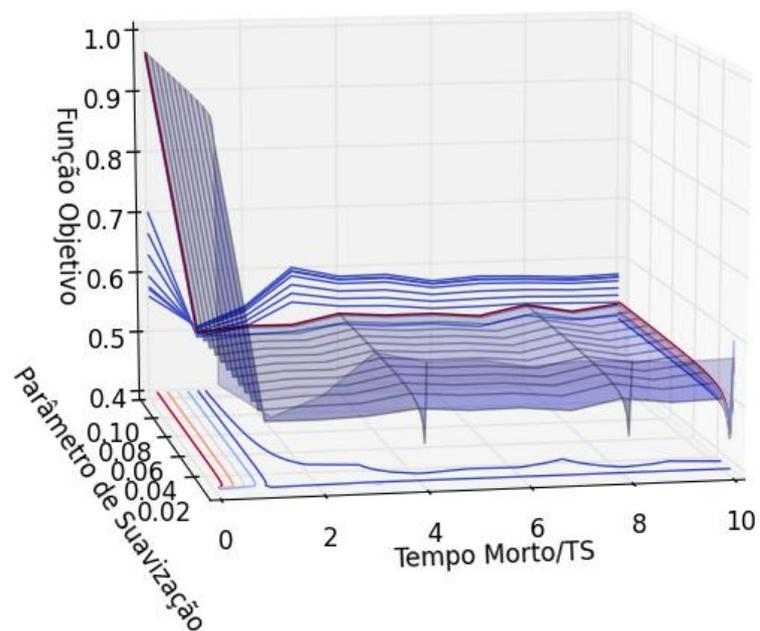


Figura 0.17: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo inicial.

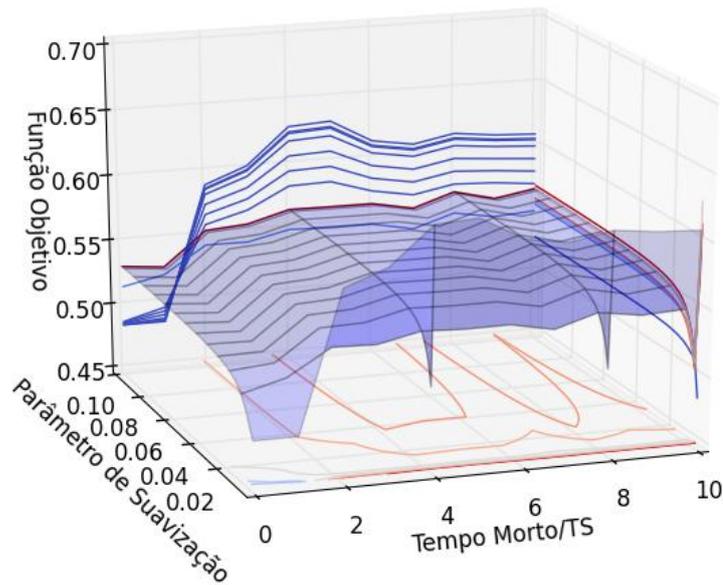


Figura 0.18: Comportamento da função objetivo de coeficiente de determinação versus parâmetro de suavização e tempo morto/TS para o modelo.

É importante destacar que sistemas com tempo morto como $1TS$ poderiam ser considerados sistemas praticamente ausentes de tempo morto. Isto ocorre pelo simples fato de que o procedimento de amostragem de sistemas de controle insere um atraso no tempo de $1TS$. Um importante aspecto é que, mesmo que o sistema em questão esteja ausente de tempo morto, a metodologia proposta foi capaz de estima-lo juntamente com o atraso inserido pelo procedimento de amostragem.

Além disso, é possível notar que alterações no modelo base durante este capítulo foram feitas de forma a aprimorar o formato da função objetivo, mesmo sem conhecimento da planta verdadeira. Ou seja, o modelo inicial foi alterado de forma arbitrária através da análise gráfica da função objetivo sem necessidade de ter algum modelo referência. Isso reforça a ideia de que não é necessário alterar o modelo base de forma a deixá-lo mais próximo do comportamento verdadeiro, e sim de forma a facilitar a estimação do parâmetro (amplificar o impacto do parâmetro no EMA).

A partir dos resultados deste capítulo de aplicação industrial é possível concluir que o método proposto apresenta boa capacidade de estimar o tempo morto, pois foi possível obter respostas muito similares ao método de identificação direta através do ARX. A grande vantagem da metodologia proposta é não necessitar de testes intrusivos, como modificações no *setpoint*. Contudo, muitas vezes são necessárias modificações consideráveis no modelo inicial de forma a obter a presença de mínimo global na função objetivo. Desta forma uma etapa de otimização do modelo inicial pode ser incluída.

Capítulo 6 – Conclusão e Trabalhos Futuros

O conhecimento sobre o tempo morto do processo permite a manutenção da estabilidade das malhas de controle através da avaliação do seu desempenho (CVM). Contribui com metodologias de identificação de sistemas lineares e distúrbios não medidos, além de facilitar o ajuste de controladores PID e DTC.

Embora seja um objeto alvo de estudo, a maior parte das técnicas presentes na literatura necessita o uso de testes intrusivos no sistema. Metodologias não intrusivas para estimação do tempo morto são inexistentes na literatura tornando o presente trabalho o único da categoria.

O objetivo da metodologia proposta é estimar o tempo morto de maneira não intrusiva em sistemas monovariáveis através do uso de dados históricos do processo e dos parâmetros de sintonia do controlador. Para avaliar a metodologia proposta, uma série de estudos de caso simulados foi considerada. A ideia foi combinar diferentes modelos, planta e sintonias de controladores a fim de considerar cenários tipicamente presentes no âmbito industrial. Resultados indicaram que a metodologia se mostrou satisfatória na estimação do tempo morto na maioria dos casos estudados, indicando valores próximos do tempo morto original dos modelos considerados.

Dentre as principais limitações da metodologia destacam-se a dependência de parâmetros externos, como suavização e do modelo inicial. A escolha do parâmetro de suavização é uma etapa crítica na metodologia proposta, limitação que é parcialmente solucionada pelo uso da função objetivo de coeficiente de determinação, uma vez que permite a formação de mínimo global. A forte influencia do modelo no formato da função objetivo pode dificultar a estimação do parâmetro tempo morto. Etapa que deve ser aprimorada de forma a permitir a automatização da metodologia.

Ainda, como limitação verifica-se forte influência do tamanho da janela de dados utilizada para aplicar a metodologia. Uma vez que funções objetivo estatísticas podem sofrer influência do número de observações. A sugestão deste trabalho para escolha do tamanho da janela é uma heurística simples que pode ser aperfeiçoada.

Embora a metodologia ainda apresente limitações, os resultados obtidos foram superiores aos encontrados quando pelo método ARX e o método de Harrison. Isso porque, todos os métodos da literatura necessitam de testes intrusivos ou perturbações no *setpoint*, ao contrario da metodologia proposta que se mostra passível de ser utilizada com conjuntos de dados históricos sem a necessidade de condições específicas. Dessa forma, a geração/busca por dados históricos apropriados não é fator limitante para o uso da técnica proposta, de modo que ela pode ser até mesmo utilizada como forma de monitoramento de malhas de controle.

A metodologia proposta também se mostrou eficiente quando aplicada a um estudo de caso industrial, cujos resultados foram similares aos obtidos com o método ARX, porém sem a necessidade de dados perturbados.

Aperfeiçoamentos no modelo ainda podem ser estudados de forma a melhorar o formato da função objetivo de coeficiente de determinação. Um possível estudo seria qual modelo favorece a função objetivo, possivelmente no domínio da frequência.

Dentre os principais trabalhos futuros destaca-se a extensão da metodologia para aplicação em sistemas multivariáveis, com controladores MPC. Outra possível aplicação seria na estimação de distúrbios não medidos ou nos outros parâmetros do modelo.

Referências

- Ahmed, S., Huang, B. & Shah, S.L., 2006. Parameter and delay estimation of continuous-time models using a linear filter. *Journal of Process Control*, 16(4), pp.323–331.
- Åström, K. & Hägglund, T., 1995. PID controllers: theory, design and tuning. *Instrument Society of America*, p.343.
- Åström, K.J., 1970. *Introduction to stochastic control theory.*, New York, NY: Academic Press.
- Åström, K.J. & Wittenmark, B., *Computer-Controlled Systems: Theory and Design, Third Edition Dover Books on Electrical Engineering* 2013 Courier Corporation, ed.,
- Babji, S. & Tangirala, A.K., 2009. Time-delay estimation in closed-loop processes using average mutual information theory. *Control and Intelligent Systems*, 37(3).
- Bezergianni, S. & Georgakis, C., 2000. Controller performance assessment based on minimum and open-loop output variance. *Control Engineering Practice*, 8(7), pp.791–797.
- Björklund, S., 2003a. *A Survey and Comparison of Time-Delay Estimation Methods in Linear Systems*,
- Björklund, S., 2003b. Analysis of a Phase Method for Time-Delay Estimation. *Electrical Engineering*.
- Björklund, S., 2003c. *Experimental Evaluation of some Cross Correlation Methods for Time-Delay Estimation in Linear Systems*.
- Björklund, S., 2003d. Experimental Evaluation of some Thresholding Methods for Estimating Time-Delays in.
- Carlemalm, C. et al., 1999. Algorithms for Time Delay Estimation Using a Low Complexity Exhaustive Search. , 44(5), pp.1031–1037.

- Carter, G.C., 1987. Coherence and time delay estimation. *Proceedings of the IEEE*, 75(2), pp.236–255.
- Desborough, L. & Harris, T., 1992. Performance assessment measures for univariate feedback control. *The Canadian Journal of Chemical Engineering*, 70(6), pp.1186–1197.
- Elnaggar, A. et al., 1989. Recursive Estimation for System of Unknown Delay. , (December), pp.1809–1810.
- Falk, J., Händel, P. & Jansson, M., 2002. Direction Finding for Electronic Warfare Systems Using the Phase of the Cross Spectral Density.
- Ferretti, G., Maffezzoni, C. & Scattolini, R., 1996. On the identifiability of the time delay with least-squares methods. *Automatica*, 32(3), pp.449–453.
- Ferretti, G., Maffezzoni, C. & Scattolini, R., 1991. Recursive estimation of time delay in sampled systems. *Automatica*, 27(4), pp.653–661.
- Fischer, B., 1999. *System identification in alternative shift operators with applications and some other topics*. Uleå University of Technology, Department of Computer Science, Electrical and Space Engineering, Signals and Systems.
- Fischer, B.R. & Medvedev, A., 1999. Laguerre domain estimation of time delays in narrowband ultrasonic echoes. *IFAC Proceedings Volumes*, 32(2), pp.4129–4134.
- Grennberg, A. & Sandell, M., 1994. Estimation of Subsample Time Delay Differences in Narrowband Ultrasonic Echoes Using the Hilbert Transform. , (September).
- Gustafsson, F., 2000. *Adaptive Filtering and Change Detection*.
- Hahn, G.J., 1972. Simultaneous Prediction Intervals for a Regression Model. *Technometrics*, 14(1), p.203.
- Harris, T.J., 1989. Assessment of Control Loop Performance. *The Canadian Journal of Chemical Engineering*, 67(5), pp.856–861.
- Harrison, C.A. & Qin, S.J., 2012. A Feedback-Invariant Approach to Time- Delay Estimation for Performance Monitoring A Feedback-Invariant Approach to Time-Delay Estimation for Performance Monitoring.
- Hero, A. et al., 1998. Highlights of statistical signal and array processing. *IEEE Signal Processing Magazine*, 15(5), pp.21–64.
- Houghton, A. & Reeve, C., 1997. Direction finding on spread-spectrum signals using the time-domain filtered cross spectral density. *IEE Proceedings-Radar, Sonar and Navigation*, pp.315–320.
- Huang, B. & Shah, S.L., 1999. *Performance Assessment of Control Loops: Theory and Applications* S. S. & B. Media, ed.,
- Ingimundarson, A. & Häggglund, T., 2000. Closed-Loop Identification of a First-Order Plus Dead-Time Model with Method of Moments. *IFAC Proceedings Volumes*, 33(10),

- pp.929–934.
- Ingimundarson, A.L., 2003. *Dead-Time Compensation and Performance Monitoring in Process Control*. Department of Automatic Control, Lund Institute of Technology (LTH).
- Isaksson, A.J., Horchl, A. & Dumont, G.A., 2001. Event-triggered deadtime estimation from closed-loop data The method. , pp.3280–3285.
- Isaksson, M., 1997. A comparison of Some Approaches to Time-selay Estimation.
- Isermann, R., 2013. *Digital Control Systems 2013* Springer Science & Business Media, ed.,
- K. Warwick, D.R., 1988. *Industrial Digital Control Systems 1988* IET, ed.,
- Kempf, A.D.O., 2003. Avaliação de Desempenho de Malhas de Controle.
- Kurz, H., 1979. Digital Parameter-adaptive Control of Processes with Unknown Constant or Timevarying Dead Time. *IFAC Proceedings Volumes*, 12(8), pp.1187–1194.
- Kurz, H. & Goedecke, W., 1981. Digital parameter-adaptive control of processes with unknown dead time. *Automatica*, 17(1), pp.245–252.
- Lima, M., 2016. *Metodologia para Estimar Distúrbios não Medidos Aplicada a Sistemas SISO*. UFRGS.
- Ljung, L., Identification for control: simple process models. In *Proceedings of the 41st IEEE Conference on Decision and Control, 2002*. IEEE, pp. 4652–4657.
- Ljung, L., 1987. Ljung L System Identification Theory for User.pdf. *PTR Prentice Hall Upper Saddle River NJ*, 25, pp.475–476.
- Mehrkanoon, S. et al., 2016. Estimating the unknown time delay in chemical processes. *Engineering Applications of Artificial Intelligence*, 55, pp.219–230.
- Montgomery, D.C., Peck, E.A. & Vining, G.G., *Introduction to Linear Regression Analysis* 2012 John Wiley & Sons, ed.,
- Nagy, P.A.J. & Ljung, L., 1991. Estimating Time-Delays Via State-Space Identification Methods. *IFAC Proceedings Volumes*, 24(3), pp.717–720.
- Nikias, C.L. & Mendel, J.M., 1993. Signal processing with higher-order spectra. *IEEE Signal Processing Magazine*, 10(3), pp.10–37.
- Normey-Rico, J.E., 2007. *Control of Dead-time Processes* 2007 Springer Science & Business Media, ed.,
- O'Dwyer, A., Time Delayed Process Model Parameter Estimation : Classification of Techniques. *International Journal*, pp.1–7.

- Oura, K., Akizuki, K. & Hanazaki, I., 1997. Estimation of order and delay time of the process in a closed-loop control system. *Electrical Engineering in Japan*, 121(2), pp.63–71.
- Pupeikis, R., 1985. Recursive Estimation of the Parameters of Linear Systems with Time Delay. *IFAC Proceedings Volumes*, 18(5), pp.787–792.
- Quazi, A., 1981. An overview on the time delay estimate in active and passive systems for target localization. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 29(3), pp.527–533.
- Seborg, D.E. et al., 2010. *Process Dynamics and Control*.
- Shinskey, F.G., 1979. *Process Control Systems*, McGraw Hill Higher Education.
- Smith, O.J.M., 1957. Closed control of loops with dead time. *Chemical Engineering Progress*.
- Swanda, A.P., 1999. *PID Controller Performance Assessment Based on Closed-loop Response Data* 1999 University of California, Santa Barbara, ed.,
- Tranter, R.L., *Design and Analysis in Chemical Research Volume 3 de Sheffield analytical chemistry* 2000 CRC Press, ed.,
- Tyler, M.L. & Morari, M., 1996. Performance monitoring of control systems using likelihood methods. *Automatica*, 32(8), pp.1145–1162.
- Wang, Q.G. & Zhang, Y., 2001. Robust identification of continuous systems with dead-time from step responses. *Automatica*, 37(3), pp.377–390.

Apêndice A – Resultados

A.1 Caso 4.4 SNR 5%

Planta A SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	5	5.2	5	5	5	5.0	5.4	5.0	4.6	5.0
Ajuste 2	5	5.1	13	5	5	5.0	11.0	5.0	4.6	5.0
Ajuste 3	23	5.0	16	5	5	5.3	5.0	6.6	5.0	5.0
Ajuste 4	5	5.0	15	5	5	5.1	5.0	12.0	4.6	5.2

Planta B SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	6.5	7.5	12	13	15	11	10.0	12	15.0	4.4
Ajuste 2	6.5	7.5	13	15	15	15	10.0	15	3.5	0.0
Ajuste 3	7.5	7.5	12	15	15	15	11.0	15	15.0	1.4
Ajuste 4	6.5	7.6	12	15	18	15	9.6	11	15.0	15.0

Planta C SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	3.7	1.7	3.5	13.0	0.91	1.9	9.1	1.9	1.8	1.9
Ajuste 2	3.6	2.2	12.0	1.2	1.40	0.0	2.3	1.8	2.2	1.8
Ajuste 3	1.8	2.1	2.2	0.0	4.10	2.8	2.7	9.4	1.8	1.9
Ajuste 4	1.8	1.9	3.5	14.0	14.00	3.2	2.3	3.3	14.0	2.2

Planta D SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	2.5	3.4	7.0	1.8	11	4.2	6.6	7.0	14.0	0
Ajuste 2	3.3	16.0	5.1	19.0	0	5.8	5.9	12.0	1.1	0
Ajuste 3	2.6	4.5	7.0	0.0	0	4.5	4.6	30.0	0.0	0
Ajuste 4	4.2	3.1	30.0	0.0	0	3.5	5.1	9.5	15.0	0

Planta E SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	3.0	7.2	4.7	21.0	2.6	4.0	6.6	4.9	3.0	0.0
Ajuste 2	2.9	2.9	4.7	2.8	2.6	5.4	3.2	5.5	19.0	2.8
Ajuste 3	3.4	3.0	5.1	2.3	2.6	3.4	3.8	6.3	2.8	2.6
Ajuste 4	3.5	3.2	4.7	26.0	2.5	2.9	3.4	6.3	3.0	22.0

Planta F SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	24.0	1.9	9.4	7.6	7.5	7.4	7.2	7.6	8.0	0.82
Ajuste 2	7.9	7.5	6.0	30.0	30.0	7.1	6.9	4.5	30.0	7.70
Ajuste 3	7.6	7.7	7.2	7.7	7.4	5.5	8.4	4.9	7.7	0.00
Ajuste 4	3.4	2.6	5.5	30.0	7.5	10.0	8.0	4.4	30.0	7.80

Planta G SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	1.3	21.0	2.8	1.4	1.2	1.9	1.2	4.0	0.0	1.4
Ajuste 2	1.8	1.7	12.0	1.8	1.1	0.0	1.2	2.0	1.8	1.2
Ajuste 3	1.3	2.0	2.7	1.3	1.4	1.3	2.0	3.1	1.5	3.2
Ajuste 4	1.8	1.3	2.1	1.4	1.2	1.4	1.6	2.8	1.2	1.3

Planta H SNR 5	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	3.4	3.7	5.3	0.8	4.4	3.8	4.3	4.1	26.0	0.0
Ajuste 2	5.3	3.7	5.1	25.0	3.5	4.0	4.0	5.6	4.9	4.6
Ajuste 3	3.6	3.5	6.8	4.4	7.1	4.6	8.9	11.0	26.0	0.0
Ajuste 4	3.2	4.2	5.3	24.0	4.9	5.9	5.2	4.2	0.0	27.0

A.2 Caso 4.4 SNR 30%

Planta A SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	5	5.0	5	4.9	5.0	15	5.2	4.6	5.3	17
Ajuste 2	23	5.1	5	5.0	5.3	5	5.4	5.0	5.0	5
Ajuste 3	5	5.0	5	5.0	5.0	5	5.4	5.0	4.6	5
Ajuste 4	5	5.0	5	5.0	4.7	5	5.4	5.2	5.0	5

Planta B SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	5.2	11.0	15	0.65	0.48	15	10	15.00	15.0	4.4
Ajuste 2	15.0	15.0	13	4.00	15.00	15	15	3.60	2.5	15.0
Ajuste 3	7.5	5.6	15	16.00	15.00	13	11	0.38	30.0	1.4
Ajuste 4	5.5	11.0	15	15.00	1.30	15	15	11.00	3.4	8.3

Planta C SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	3.9	2.0	3.9	1.90	2.10	3.0	4.6	3.9	1.9	4.3
Ajuste 2	4.0	1.9	2.0	0.97	0.00	13.0	2.6	2.1	0.0	1.9
Ajuste 3	0.0	2.1	4.4	1.70	0.00	2.3	3.3	1.8	0.0	2.0
Ajuste 4	1.5	3.7	16.0	4.00	0.95	1.8	2.0	5.0	0.0	2.7

Planta D SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	2	0	0.0	0	0.0	7.5	0.0	0.0	0	0.0
Ajuste 2	0	0	3.7	0	0.0	0.0	5.6	1.5	0	1.3
Ajuste 3	0	0	0.0	0	0.0	1.8	4.6	0.0	0	0.0
Ajuste 4	0	0	0.0	0	8.9	0.0	2.8	0.0	0	0.0

Planta E SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	2.9	5.8	6.1	8.9	2.8	4.0	3.8	2.7	2.7	2.6
Ajuste 2	5.1	3.0	2.9	0.0	2.7	4.3	3.3	2.6	2.8	9.1
Ajuste 3	2.8	3.9	4.5	2.7	2.8	2.7	3.2	2.7	2.6	2.5
Ajuste 4	2.7	2.8	2.9	2.6	2.4	5.1	3.3	2.8	0.0	2.7

Planta F SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	7.7	0.0	7.6	0	0.0	15.0	7.4	7.7	0.39	0.0
Ajuste 2	7.7	7.8	7.7	0	0.0	9.1	7.8	0.0	0.00	7.8
Ajuste 3	1.3	30.0	11.0	0	0.0	7.6	4.8	7.6	7.70	7.7
Ajuste 4	3.2	7.6	7.5	0	7.6	7.7	8.0	7.7	0.00	14.0

Planta G SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	2.5	1.3	1.5	1.1	1.3	1.5	1.3	1.1	1.1	1.4
Ajuste 2	1.4	1.9	2.1	1.8	1.2	1.6	1.6	1.8	1.5	0.0
Ajuste 3	21.0	1.3	11.0	1.3	1.3	1.2	1.7	19.0	1.2	0.0
Ajuste 4	1.5	1.3	1.9	1.2	0.0	1.3	1.7	1.6	1.1	1.2

Planta H SNR 30	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10
Ajuste 1	3.6	3.4	6.7	6.2	27.0	5.0	4.9	0.72	0.0	3.5
Ajuste 2	3.2	2.9	0.0	2.2	0.0	3.2	4.5	2.50	0.0	0.0
Ajuste 3	5.9	4.9	5.4	3.3	3.8	4.4	3.9	0.00	0.5	0.0
Ajuste 4	3.4	5.2	3.0	3.2	3.7	7.1	4.2	4.60	3.3	0.0

