



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
ENG07053 - TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA
QUÍMICA



Testes com uma Estrutura PID para Inferência de Propriedades

Autor: Lívia de Souza Schaumlöffel

Orientador: Professor Dr. Pedro Rafael Bolognese Fernandes

Porto Alegre, dezembro de 14

Sumário

Sumário	ii
Agradecimentos	iv
Resumo	v
Lista de Figuras	vi
Lista de Tabelas	vii
Lista de Símbolos	viii
Lista de Abreviaturas e Siglas	ix
1 Introdução	1
2 Revisão Bibliográfica	2
2.1 Sensores Virtuais	2
2.2 Modelos Baseados em Dados	3
2.2.1 Modelos baseados em PCA	3
2.2.2 Modelos baseados em PLS	3
2.2.3 Modelos baseados em Redes Neurais	4
2.2.4 Outros métodos	4
2.3 Modelos Baseados em Princípios Fundamentais	5
2.3.1 Filtro Kalman (KF)	6
2.3.2 Estimação por Horizonte Móvel (MHE)	6
2.3.3 Mínimos Quadrados Recursivos (RLS)	6
3 Metodologia	8
3.1 Ferramentas utilizadas	8
3.2 Implementação da estrutura PID na forma de blocos	8
3.3 Sistemas analisados	9
3.3.1 Estimação do ganho do processo	9
3.3.2 Estimação da constante de tempo	10
3.4 Critérios de comparação	10
4 Resultados e Discussão	12
4.1 Estudo da estimação do ganho	12
4.1.1 Estudo da sintonia	12
4.1.2 Influência da taxa de variação do ganho	14
4.1.3 Efeito de distúrbios	14
4.1.4 Monitoração da saída x Monitoração do parâmetro	15
4.2 Estudo da estimação da dinâmica (constante de tempo dominante)	16
4.2.1 Estudo da sintonia	16
4.2.2 Efeitos de distúrbios	19
4.2.3 Monitoração da saída x Monitoração do parâmetro	20
5 Teste em uma Planta Real	21
5.1 Descrição da Planta de Seis Tanques Esféricos	21
5.2 Modelagem e implementação do PID junto à planta	22

5.3	Ajuste dos parâmetros	22
5.4	Resultados do teste na planta	23
6	Conclusões e Trabalhos Futuros	26
7	Referências	27
8	Apêndice	29

Agradecimentos

Primeiramente à minha família pela base, pelo incentivo, suporte e paciência ao longo do curso. Palavras não são suficientes para demonstrar toda a gratidão, pois sem a ajuda de vocês não seria possível chegar até aqui.

Aos amigos pela parceria e por proporcionarem bons momentos fazendo essa jornada mais alegre e menos cansativa. Em especial aos amigos que fiz na UFRGS por também ajudarem nos estudos, compartilhando as dificuldades e tornando o caminho menos solitário. Entre eles, um especial agradecimento aos amigos do Lab K125 pelos cafés mais divertidos da faculdade.

À UFRGS e aos professores e funcionários do Departamento de Engenharia Química pelo conhecimento transmitido e pelo trabalho que realizam apesar das dificuldades.

Ao professor Pedro Fernandes pela orientação nesse trabalho.

Resumo

Neste trabalho foi testada a utilização de uma estrutura do tipo PI/PID para estimação de parâmetros de modelos de processos. Os parâmetros estimados foram o ganho e a constante de tempo de uma função de transferência de primeira ordem. O estudo foi realizado através de simulações utilizando o programa MATLAB, onde o PID e os modelos foram implementados. O objetivo foi avaliar a capacidade estrutura para gerar estimativas corretas, bem como os ajustes necessários e a confiabilidade da previsão frente a distúrbios na entrada da função. Além disso, o PID foi testado para estimativa do coeficiente de descarga de um modelo fenomenológico de tanque esférico e aplicado para inferência em tempo real desse coeficiente em um dos tanques da Planta Laboratorial de Seis Tanques Esféricos do DEQUI-UFRGS. Para a maioria dos casos simulados, a estrutura PID previu corretamente o valor do parâmetro, desde que com sintonia adequada. Se mostrou eficaz também na previsão do coeficiente de descarga de um tanque, em tempo real.

Lista de Figuras

Figura 2.1: Arquitetura da abordagem de rede neural baseada em PCA. Retirado de (Warne <i>et al.</i> , 2004).....	4
Figura 2.2: Distribuição dos métodos usados no desenvolvimento de sensores baseados em dados. Adaptado de (Kadlec <i>et al.</i> , 2009)	5
Figura 3.1: Fluxograma da associação entre PID, modelo e processo.....	8
Figura 3.2: Estrutura PID implementada em <i>Simulink</i>	9
Figura 3.3: Estrutura implementada para estimação do ganho de uma função de transferência.....	9
Figura 3.4: Estrutura implementada para estimação da constante de tempo de uma função de transferência.....	10
Figura 3.5: Integrais do sinal do erro implementadas em <i>Simulink</i>	11
Figura 4.1: Estimativa do ganho para diferentes valores de K_c	12
Figura 4.2: Estimativa do ganho com e sem a ação integral ($K_c=10$, $\tau_i=0,01$)	13
Figura 4.3: Degrau na entrada de 1 para 30 (A) e de 1 pra -0,01 (B) em 10s	15
Figura 4.4: Estimativa da constante de tempo para diferentes valores de τ_i , com $K_c=10$..	16
Figura 4.5: Estimativa da constante de tempo com e sem a ação derivativa ($K_c=50$, $\tau_i=0,1$, $\tau_D=15$).....	18
Figura 4.6: Inferência com degraus na entrada de 1 para 0,001 (A) e 1 para -5 (B) aplicados em 50s. $\tau_i=1$, $K_c=50$	19
Figura 4.7: Inferências com degrau na constante de tempo de 50 para 100 (A) e 50 para 1 (B) aplicados em 50s. $\tau_i=1$, $K_c=50$	19
Figura 5.1: Planta Laboratorial de Seis Tanques Esféricos.....	21
Figura 5.2: Sistema implementado em <i>Simulink</i> para estimativa do CD.....	22
Figura 5.3: Inferência para o CD com $K_c=-15$, $\tau_i=10$ (A) e $K_c=15$, $\tau_i=10$ (B).....	23
Figura 5.4: Efeitos dos parâmetros do PID na inferência do parâmetro e na resposta do nível	23
Figura 5.5: Nível medido na planta e previsto pelo modelo.....	24
Figura 5.6: CD estimado pelo PID.....	24
Figura 5.7: Vazão de alimentação fornecida à planta.....	25

Lista de Tabelas

Tabela 3.1: Critérios de desempenho avaliados	11
Tabela 4.1: Comparativo da inferência do ganho crescente com o tempo a uma taxa de $0,005s^{-1}$ a diferentes τ_I com $K_c=10$	13
Tabela 4.2: Comparativo da inferência do ganho crescente com o tempo a uma taxa de $0,005s^{-1}$ a diferentes K_c com $\tau_I=0,01$	14
Tabela 4.3: Melhor ajuste obtido para diferentes taxas de variação do ganho	14
Tabela 4.4: Comparativo da resposta a diferentes taxas de variação do ganho	14
Tabela 4.5: Comparativo do efeito de diferentes degraus na entrada da função, aplicados dos 10s até 50s	15
Tabela 4.6: Comparação das respostas real e estimadas para parâmetro e saída com ganho crescente com o tempo a uma taxa de $0,005s^{-1}$ e $K_c=10$	16
Tabela 4.7: Critérios de desempenho para diferentes τ_I	17
Tabela 4.8: Critérios de desempenho para diferentes K_c	17
Tabela 4.9: Critérios de desempenho com e sem a ação derivativa ($K_c=50$, $\tau_I=0,1$, $\tau_D=15$)	18
Tabela 4.10: Critérios de desempenho para constantes de tempo diferentes	18
Tabela 4.11: Comparação das respostas real e estimadas para parâmetro e saída com $\tau=50$ e $\tau_I=0,1$	20

Lista de Símbolos

K_c – Ganho do PID

T_I – Constante de tempo integral

T_D – Constante de tempo derivativo

N – Horizonte de predição

t_A – Tempo de assentamento

h – Nível do tanque

F_{in} – Vazão volumétrica de alimentação

CD – Coeficiente de descarga

D – Diâmetro do tanque

A₀ – Área da seção do orifício de descarga

g – Aceleração da gravidade

Lista de Abreviaturas e Siglas

FPM – First Principle Model

PCA – Principal Component Analysis

PLS – Partial Least Squares

ANN – Artificial Neural Networks

MLP – Multi-Layer Perceptron

RBFN – Radial Basis Function Network

SOM – Self-Organizing Network

RNN – Recurrent Neural Network

SVM – Support Vector Machines

NFS – Neuro-Fuzzy System

KF – Kalman Filter

EKF – Extended Kalman Filter

UKF – Unscented Kalman Filter

MHE – Moving Horizon Estimation

RLS – Recursive Least Squares

PID – Proporcional Integral Derivativo

IAE – Integral do valor absoluto do erro

ITAE – Integral do tempo multiplicado pelo valor absoluto do erro

ISE – Integral do valor quadrático do erro

1 Introdução

Na economia atual, os mercados estão cada vez mais competitivos e levam as indústrias à constante busca de redução de custos. Além disso, a crescente preocupação com o meio ambiente e desenvolvimento sustentável, bem como a cobrança por qualidade dos produtos por parte dos consumidores são outros desafios para as empresas. Para adequar os processos às novas demandas, as indústrias de processos necessitam de um controle cada vez mais eficiente do processo, de forma a reduzir perdas, emissões e atender às especificações dos produtos.

Um grande desafio do controle de processos são as variáveis e propriedades de difícil medição. Estratégias de controle avançadas dependem de sensores virtuais, construídos a partir de um modelo do processo, para prever o comportamento dessas variáveis e assim antecipar as ações de controle. Outro uso desses sensores é a previsão de propriedades do produto, de forma a permitir o acompanhamento e controle das mesmas. Dada a complexidade dos processos e a variação dos mesmos ao longo do tempo, há necessidade de estimar alguns parâmetros dos modelos para que os mesmos representem com precisão o processo e forneçam previsões corretas. Exemplos desses parâmetros são o coeficiente global de troca térmica em trocadores de calor e a atividade catalítica em reatores heterogêneos.

As ferramentas atualmente utilizadas para estimação de parâmetros, apesar de consolidadas, apresentam dificuldades ao se trabalhar com sistemas não-lineares e ferramentas adequadas a esses sistemas geralmente necessitam de grande capacidade computacional, pois a maioria destas técnicas é complexa.

O objetivo desse trabalho é avaliar a capacidade da estrutura PI/PID para inferência *on-line* de parâmetros de sistema dinâmicos. Deseja-se também verificar se o conhecimento disponível para o ajuste de PID's, quando utilizados para controle de processos, serão válidos no uso do mesmo como estimador. A base da proposta deste trabalho, ou seja, o uso de uma estrutura do tipo PI/PID para a estimação de parâmetros de modelos de processo, parte da conhecida analogia entre controle e estimação de estados/parâmetros (Kailath, 1979). A estrutura proposta será testada em simulações e também na estimação em tempo de real de parâmetros na Planta Laboratorial de Seis Tanques Esféricos do Departamento de Engenharia Química da UFRGS

No capítulo 2 será feita uma revisão dos atuais métodos de construção dos sensores virtuais e ferramentas para estimação de parâmetros. No capítulo 3 são descritas as metodologias para implementação e avaliação da estrutura PID. O capítulo 4 apresenta os resultados dos testes com a função de transferência, enquanto o 5 refere-se ao teste de aplicação prática, descrevendo a planta e resultados do teste. Por último, o capítulo 6 traz as conclusões e as perspectivas para trabalhos futuros.

2 Revisão Bibliográfica

Neste capítulo é apresentada uma revisão geral dos sensores virtuais, com ênfase nas técnicas para desenvolvimento dos modelos por trás dos mesmos. Definições são fornecidas, bem como aplicações práticas e algumas comparações. Por último, focando no objetivo do trabalho, é feita uma revisão das ferramentas disponíveis para estimação de parâmetros.

2.1 Sensores Virtuais

Sensores virtuais são ferramentas muito úteis para operação e controle eficientes de processos químicos. Na literatura encontram-se trabalhos que abordam diferentes métodos para a geração dos mesmos. Esses sensores são basicamente algoritmos que estimam o valor da propriedade de interesse com base em medições físicas do processo. Boa parte destes sensores está baseada em modelos preditivos do processo, também denominados modelos inferenciais.

Entre seus usos estão: predição on-line de propriedades e variáveis de medição difícil, demorada ou cara, monitoramento e detecção de falhas no processo e detecção de falhas em sensores reais (Kadlec *et al.*, 2009). Quando utilizados na predição de propriedade e variáveis difíceis de medir, esses sensores permitem a implementação de controle inferencial.

Fortuna *et al.* (2005) enumeram as propriedades que tornam esses sensores atrativos. Entre elas: oferecem uma alternativa de baixo custo aos medidores tradicionais; conseguem trabalhar em paralelo com esses medidores, podendo ser usados para detecção de falhas nos mesmos; são facilmente implementados no hardware existente; permitem estimativas em tempo real, superando o tempo morto introduzido por sensores que demandam elevado tempo de mediação, tais como os cromatógrafos, aumentando a performance do sistema de controle.

Apesar das vantagens já citadas, os sensores virtuais também apresentam problemas. Kano e Fujiwara (2013) enfatizam a deterioração da performance do sensor ao longo do tempo devido a mudanças nas características do processo e condições de operação como, por exemplo, incrustações, desativação de catalisador ou mesmo fatores ambientais externos. Em adição a isso, em algumas aplicações, as diferenças entre equipamentos devem ser consideradas e, muitas vezes, um sensor desenvolvido para um equipamento não funciona em outro.

Kadlec *et al.* (2009) dividem os sensores virtuais usados na indústria de processos em duas categorias: baseados em modelos e baseados em dados. Os analisadores baseados em modelos, também chamados caixa-branca, são geralmente derivados de modelos de princípios básicos que descrevem física e quimicamente o processo por meio de equações algébricas e diferenciais. Os parâmetros das equações são determinados por técnicas diversas. São modelos desenvolvidos primeiramente para o projeto da instalação industrial e têm foco na descrição do estado estacionário dos processos. São menos usados como sensores virtuais devido suas características que demandam grande conhecimento do processo para correta descrição do mesmo. Os modelos baseados em dados surgem como alternativa nos casos em que o conhecimento do processo não é suficiente. São modelos empíricos, obtidos a partir dos dados de processos medidos na planta e armazenados ao longo do tempo, ou seja, sendo de aplicação mais rápida e em

geral mais adequados ao processo. São também denominados modelos caixa-preta. Existem também sensores construídos a partir da combinação dos dois modos, conhecidos por caixa-cinza.

Vários trabalhos abordam essa modelagem em conjunto, onde geralmente um modelo de princípios fundamentais (FPM) é construído e abordagens baseadas em dados são usadas para compensar as características não consideradas no modelo matemático e lidar com a variação do processo ao longo do tempo. No trabalho de Jia *et al.* (2011) uma abordagem híbrida é comparada com um FPM puro e também com um modelo baseado em dados. A abordagem híbrida obteve uma melhor predição, com o menor dos erros entre os métodos.

2.2 Modelos Baseados em Dados

Para construção dos modelos inferenciais baseados em dados, as técnicas mais utilizadas são duas: regressões estatísticas e modelagem por inteligência artificial (Warne *et al.*, 2004). Entre as técnicas estatísticas estão a análise dos componentes principais (PCA) e a aproximação por mínimos quadrados parciais (PLS). Entre as técnicas que se utilizam inteligência artificial, sobressaem-se as redes neurais artificiais (ANN). Ainda, existem variantes e adaptações desses métodos que surgem para se adequar a problemáticas específicas de cada caso. Em muitos trabalhos, há também a aplicação de mais de uma técnica em conjunto para criação do modelo.

2.2.1 Modelos baseados em PCA

A ideia central da Análise dos Componentes Principais é reduzir a dimensionalidade de um conjunto de dados, que consiste de um grande número de variáveis inter-relacionadas, enquanto retém a maior variação possível do conjunto de dados original. Para isso, é feita a transformação para um novo conjunto de variáveis – os componentes principais – que são não-correlatas e ordenadas de maneira que retêm a maior parte da variação presente nas variáveis originais (Warne *et al.*, 2004).

Um dos problemas do algoritmo de PCA é que só consegue lidar com relações lineares dos dados. Para contornar esse problema, surgiram extensões do algoritmo original. São exemplos o PCA Recursivo (Li *et al.*, 2000), PCA de Janela-Móvel (Wang *et al.*, 2005) e Time-Lagged PCA (Lee *et al.*, 2004). Essas extensões são denominadas versões adaptativas. Em trabalhos recentes, a análise dos componentes principais geralmente tem sido aplicada na etapa de pré-processamento dos dados, seguida pelos atuais métodos de aprendizado computacional para obtenção da inferência (Kadlec *et al.*, 2009).

2.2.2 Modelos baseados em PLS

A aproximação por mínimos quadrados parciais é um método de regressão linear. Surgiu em torno de 1975 por Herman Wold para a modelagem de conjuntos de dados complexos em termos conjunto de matrizes. Incluía também um algoritmo simples, mas eficiente, de estimar os parâmetros nesses modelos. Esse algoritmo foi chamado NIPALS (Non-linear Iterative Partial Least Squares) (Wold *et al.*, 2001).

O potencial do PLS foi reconhecido e se tornou um método popular usado como ferramenta de modelagem em várias aplicações onde as variáveis de processo são altamente correlatas. A razão da popularidade reside justamente no fato do método ser capaz de lidar com grande quantidade de dados colineares e também porque o modelo

resultante leva em conta a relação entre as variáveis de entrada e saída. O algoritmo decompõe simultaneamente os espaços de entrada e saída enquanto mantém a ortogonalidade constante. Isso resulta numa previsão mais precisa das variáveis difíceis de medir do que por PCA, que explora apenas as variáveis de entrada (Kadlec *et al.*, 2011).

Vários trabalhos na literatura se utilizam de modificações feitas no algoritmo original de PLS afim de lidar com relações não-lineares. Kano e Fujiwara (2013) colocam que a performance dos modelos PLS pode ser melhorada ao levar em conta a dinâmica do processo. Para isso, a informação em instantes de tempo anteriores é usada como entrada em adição à informação presente. Essa abordagem é chamada PLS dinâmico. Foi proposto por Galicia *et al.* (2011) que teoricamente um estimador dinâmico é capaz de adequadamente capturar a dinâmica do processo se o horizonte passado é longo o suficiente. Nesse mesmo trabalho eles propuseram um PLS dinâmico de ordem reduzida para diminuir o número de variáveis atrasadas requeridas num PLS dinâmico e aplicaram o mesmo em um digestor Kamyrr.

2.2.3 Modelos baseados em Redes Neurais

As redes neurais artificiais surgiram com o objetivo de construir modelos computacionais simulando o funcionamento dos neurônios, que são a unidade básica de processamento de informações no sistema nervoso humano. O objetivo da rede é coletar informações de entrada e processá-la gerando uma informação de saída (Kadlec *et al.*, 2009).

A modelagem baseada nas redes neurais é uma estratégia consolidada e tem sido muito utilizada em grande número de aplicações industriais quando a estimação das variáveis da planta é requerida em tempo real para monitoramento e/ou controle (Fortuna *et al.*, 2005).

2.2.4 Outros métodos

Entre as abordagens que utilizam mais de uma técnica para a obtenção da inferência, os modelos que combinam PCA com redes neurais são bastante difundidos. Um exemplo é o trabalho de Warne *et al.* (2004) que utiliza PCA para seleção das variáveis e redes neurais para correlação e obtenção da inferência, conforme ilustrado na Figura 2.1. Um estudo de caso foi feito num processo de revestimento e secagem, onde se observou melhora na performance do modelo se comparado ao uso de rede neural somente.




Figura 2.1: Arquitetura da abordagem de rede neural baseada em PCA. Retirado de (Warne *et al.*, 2004)

A Figura 2.2 mostra a distribuição dos métodos para desenvolvimento dos sensores virtuais baseados em dados, considerando os artigos revisados por Kadlec *et al.* (2009).




Figura 2.2: Distribuição dos métodos usados no desenvolvimento de sensores baseados em dados. Adaptado de (Kadlec *et al.*, 2009)

2.3 Modelos Baseados em Princípios Fundamentais

Uma vez que descrevem o processo através de equações fenomenológicas, os sensores baseados em modelos de princípios fundamentais permitem a extrapolação da predição quando as condições de processo mudam. Cada modelo é único, pois cada processo tem equações próprias que descrevem seu comportamento. Um problema chave no desenvolvimento desses modelos, seja dinâmico ou de estado estacionário, é a estimação de parâmetros.

O problema geral da estimação de parâmetros consiste em adequar um modelo a um conjunto de medidas. Dado um modelo do processo com alguns parâmetros desconhecidos, um estimador de parâmetros calcula os valores que tornam as saídas previstas pelo modelo o mais próximo possível dos valores medidos das saídas da planta. Na estimação de parâmetros on-line, um modelo é ajustado às medidas de operação do processo obtidas no passado. Informações precisas dos parâmetros são importantes para garantir uma operação segura e eficiente. Além disso, parâmetros num modelo matemático conferem ao modelo flexibilidade para se adequar às medições (Soroush, 1998).

Entre os métodos já desenvolvidos, Soroush (1998) lista os seguintes:

- Baseados na predição do erro – como o estimador gradiente, o estimador por mínimos quadrados padrão e o estimador por mínimos quadrados com taxa de esquecimento exponencial;
- Via estimação de estados – o método requer um modelo dinâmico para cada um dos parâmetros desconhecidos a ser estimado. Uma vez que modelos apropriados para os parâmetros são escolhidos, um estimador de estados, por exemplo, Filtro de Kalman Extendido, é usado para estimar o parâmetro que aparece como um subconjunto das variáveis de estado dos modelos combinados de processo e parâmetros. Esse método tem sido largamente utilizado em processos químicos e bioquímicos;

- Via otimização on-line – a estimativa dos parâmetros é obtida pela resolução on-line de um problema de minimização como a soma de erros quadrados. É um método difícil de implementar e computacionalmente dispendioso, porém permite incluir restrições na estimação.
- Via inversão do modelo – inclui uma inversão do modelo do processo e a cada instante de tempo calcula estimativas dos parâmetros pelo mínimo quadrado do erro usando medidas on-line imediatamente disponíveis.
- Métodos calorimétricos – aplicáveis para a determinação de parâmetros térmicos e cinéticos de processo, os quais são estimados on-line via balanços simples de massa e energia. São muito populares na indústria de processos e disponíveis em pacotes comerciais de programas.

Abaixo são brevemente descritas as ferramentas para estimação de parâmetros mais comuns na literatura.

2.3.1 Filtro Kalman (KF)

O Filtro Kalman surgiu em 1960 e desde então tem sido fortemente usado porque é simples de implementar e fornece estimativas ótimas para sistemas lineares com erros de medida gaussianos. Uma vez que muitos processos químicos são não-lineares, é empregada uma modificação deste método, chamado de Filtro Kalman Extendido (EKF), baseada na linearização recursiva do modelo não-linear a cada instante de amostragem do filtro (Daum, 2005). Outro obstáculo é a consideração de distribuição gaussiana de erros no sistema, inerente ao KF, que nem sempre é verdadeira e pode ser limitante algumas vezes. Progressos têm sido feitos nas duas frentes. Muitos artigos descrevem algumas potenciais armadilhas do KF e várias alternativas ao KF foram propostas (Lee e Lee, 2014). No entanto, Lee e Lee (2014), na revisão que fazem sobre o controle de processos químicos, afirmam que, apesar de popular, o EKF tem mostrado baixa performance algumas vezes, especialmente nas fases iniciais de operação, quando a estimativa, e assim os modelos linearizados, são altamente imprecisos.

O trabalho de Daum (2005) faz uma extensa comparação entre os filtros usados para estimação. Entre os filtros discutidos estão EKF, UKF (*Unscented Kalman Filter*), Filtro de Partículas e outros filtros não-lineares, esses últimos que começam a ser mais utilizados recentemente devido ao aumento da capacidade computacional.

2.3.2 Estimação por Horizonte Móvel (MHE)

Estimação de horizonte móvel é uma estratégia bem conhecida para estimação com restrição. A ideia geral é estimar o atual estado do sistema usando diretamente somente os últimos N estados e medidas, onde N é o comprimento do horizonte. Desta forma, esse método diminui a capacidade computacional requerida. No caso de um sistema linear e gaussiano, a MHE se reduz exatamente ao Filtro Kalman (Rawlings e Bakshi, 2006).

2.3.3 Mínimos Quadrados Recursivos (RLS)

O algoritmo RLS é baseado na minimização da soma dos erros de predição ao quadrado, onde parâmetros estimados do modelo do processo são aprimorados progressivamente com cada novo dado de processo adquirido. Devido sua simplicidade e rápida convergência quando propriamente aplicado, o algoritmo de mínimos quadrados

recursivos (RLS) é, sem dúvidas, a técnica mais popular de estimação de parâmetros on-line usada em controle adaptativo. A habilidade do RLS no processamento de dados em tempo real para produzir atualizações sequenciais do parâmetro do modelo é o fator crucial para a implementação do controle adaptativo (Kuen *et al.*, 2010).

Além dos estimadores já abordados, outros métodos para lidar com restrições e não-linearidades são encontrados na literatura. Exemplos são: Reconciliação de dados não-linear recursivo dinâmico, Filtro Kalman Conjunto, Filtro de Partículas Limitado, Estimação por horizonte móvel de passo avançado.

Um uso do PID como estimador é encontrado no trabalho de Choi (2007), onde o PID é utilizado como estimador de estados para um sistema Lagrangiano. O PID proposto é descrito por equações e aplicado a um exemplo numérico de um pêndulo simples para avaliar a performance, mostrando a efetividade do mesmo.

No entanto, essa abordagem e construção do PID é diferente da que se propõe esse trabalho. Trabalhos que abordem o uso de estruturas PID para estimação de parâmetros no desenvolvimento de sensores virtuais para a indústria de processos não foram encontrados na literatura.

3 Metodologia

Para o uso da estrutura PID na inferência de parâmetros, é necessário um modelo do processo, no qual uma das entradas do mesmo seja o parâmetro a se determinar. A inferência é dada pela Equação 3.1, onde p é o valor do parâmetro, y a saída medida do processo e y_{mod} a predição do modelo para a saída.

$$p = p_0 + Kc(y - y_{mod}) + \frac{1}{\tau_I} \int_0^t (y - y_{mod}) + \tau_D \frac{d(y - y_{mod})}{dt} \quad (3.1)$$

A Figura 3.1 mostra como o PID e o modelo são associados para geração da inferência. A fim de verificar o funcionamento da técnica em uma possível estratégia combinada controlador/estimador, uma entrada de controle será considerada tanto para o processo quanto para o modelo.




Figura 3.1: Fluxograma da associação entre PID, modelo e processo

A viabilidade da estrutura PID para inferência de parâmetros foi avaliada através de simulações e comparação de critérios de desempenho. Neste capítulo são descritas as ferramentas utilizadas, a implementação, os modelos testados, bem como os critérios avaliados.

3.1 Ferramentas utilizadas

Os testes foram realizados a partir do software MATLAB® 7.12.0.635 e em uma de suas plataformas chamada *Simulink*.

O MATLAB® é um ambiente integrado que combina computação numérica, gráficos e uma linguagem de programação de alto nível. O MATLAB inclui centenas de funções que permitem aplicações desde as mais simples às mais complexas.

O *Simulink* é uma extensão gráfica do MATLAB para modelagem e simulação de sistemas. No *Simulink*, os sistemas são representados graficamente sob a forma de diagrama de blocos. O ambiente do *Simulink* permite a implementação de uma estrutura em forma de blocos que suporta simulação e desenvolvimento de modelos dinâmicos e o teste de sistemas de controle. O *Simulink* é totalmente integrado com o MATLAB e os dados podem ser facilmente transferidos entre os dois.

3.2 Implementação da estrutura PID na forma de blocos

A estrutura do PID foi implementada no *Simulink* na forma paralela clássica, ou forma padrão, conforme pode ser visto na Figura 3.2. Essa é a forma mais utilizada em controle de processos e foi utilizada para facilitar a analogia com uma malha de controle.

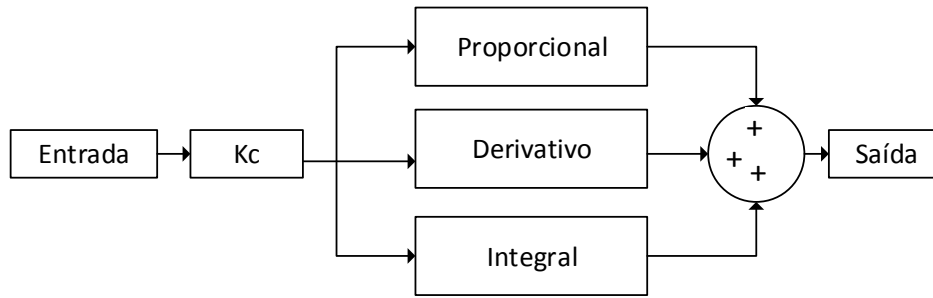


Figura 3.2: Estrutura PID implementada em *Simulink*

Esta estrutura em forma de blocos é equivalente à equação 3.2, onde α é um parâmetro do filtro derivativo, usualmente selecionado como 0,15.

$$C(s) = K_C \left(1 + \frac{1}{\tau_I s} + \frac{\tau_D s}{\alpha \tau_D s + 1} \right) \quad (3.2)$$

3.3 Sistemas analisados

Como forma de teste, a estrutura proposta foi utilizada para estimar o ganho e a constante de tempo de uma função de transferência de primeira ordem sem tempo morto em simulação (equação 3.3).

$$G(s) = \frac{K}{\tau s + 1} \quad (3.3)$$

3.3.1 Estimação do ganho do processo

Para estimativa do ganho, a função foi implementada no *Simulink* em forma de blocos junto à estrutura PID, conforme Figura 3.3. Os testes foram feitos para estimar um ganho crescente ao longo do tempo. Por tentativa e erro foi feita a sintonia do PID, determinando os valores de K_c , τ_I e τ_D que geram inferência do ganho mais próxima ao valor real. Sem alterar a sintonia, variações na taxa de crescimento do parâmetro e efeitos de distúrbios na entrada da função foram avaliados. Para fins de comparação foi fixado um tempo de 50 segundos para todas simulações.

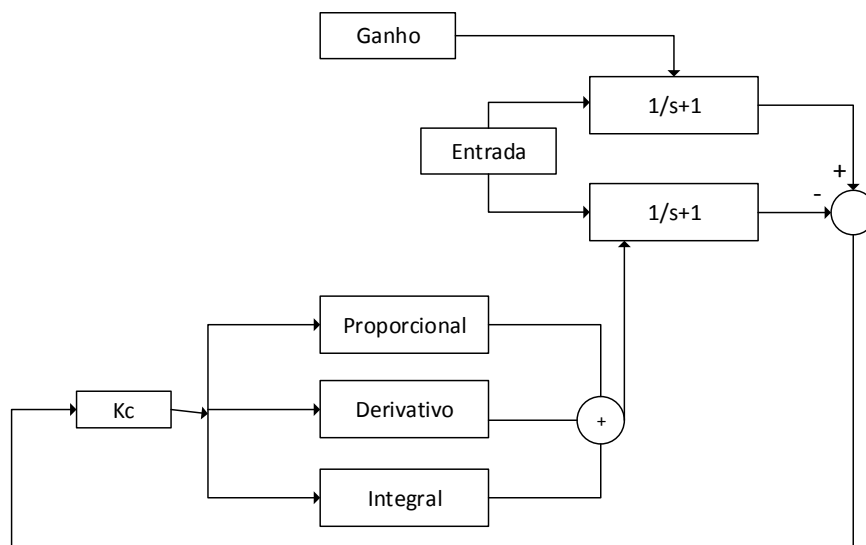


Figura 3.3: Estrutura implementada para estimação do ganho de uma função de transferência

3.3.2 Estimação da constante de tempo

Para inferência da constante de tempo, a mesma função de transferência foi implementada na forma de uma *S-Function* no *Simulink*. Foi gerado o arquivo com a função (*sistema_lin.m*) que tem duas entradas, a entrada padrão de controle e a constante de tempo. A Figura 3.4 mostra como foi feita a ligação entre o PID e a *S-Function* para inferência da constante de tempo. A rotina em MATLAB para a *S-Function* é apresentada no Apêndice A.

Assim como para a estimativa o ganho, foi avaliada a sintonia do PID por tentativa e erro. Após, foram aplicados distúrbios tanto na entrada como na constante de tempo e avaliados seus efeitos nos critérios de desempenho. Todas as simulações foram feitas com um tempo padrão de 100 segundos.

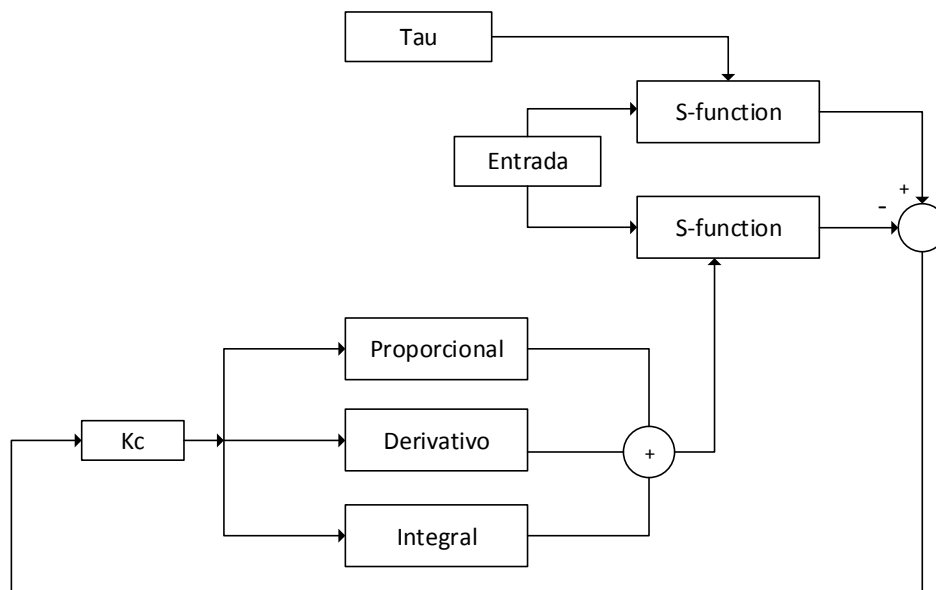


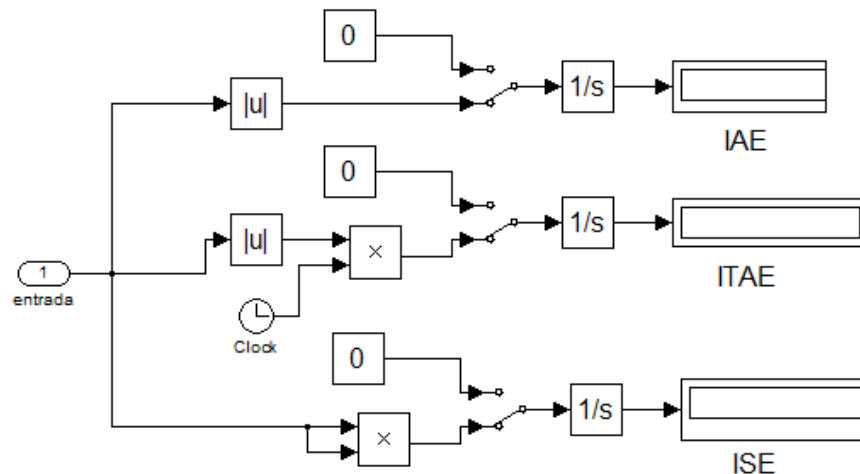
Figura 3.4: Estrutura implementada para estimação da constante de tempo de uma função de transferência

3.4 Critérios de comparação

Para avaliar a inferência obtida, os critérios comparados foram o offset e as integrais do sinal do erro. Esses critérios foram escolhidos por sua simplicidade e facilidade em identificar se a inferência está correta. O offset permite ver se, ao final de determinado tempo, a inferência atingiu o valor correto do parâmetro. As integrais do erro consideram a diferença entre o real e o estimado ao longo de todo o tempo de simulação. A Tabela 3.1 apresenta a definição desses critérios e a Figura 3.5 mostra como foram implementados na estrutura de blocos.

Tabela 3.1: Critérios de desempenho avaliados

Offset	É a diferença entre a inferência e o valor real do parâmetro ao final do tempo de simulação.	Offset = parâmetro – inferência
Integral do erro absoluto (IAE)	Integral do valor absoluto do sinal de erro no tempo. É equivalente à soma das áreas acima e abaixo do valor de referência (Marlin, 1995).	$IAE = \int_0^{\infty} e(t) dt$
Integral do erro absoluto ponderado no tempo (ITAE)	Integral do tempo multiplicado pelo valor absoluto do sinal de erro no tempo. Este índice penaliza erros que se mantêm no tempo (Marlin, 1995).	$ITAE = \int_0^{\infty} t \cdot e(t) dt$
Integral do erro quadrático (ISE)	Integral do quadrado do sinal de erro no tempo. Este índice, por definição, penaliza mais, valores maiores do sinal de erro (Marlin, 1995).	$ISE = \int_0^{\infty} [e(t)]^2 dt$

**Figura 3.5:** Integrais do sinal do erro implementadas em *Simulink*

Em alguns casos, para escolha da melhor sintonia foi medido também o tempo de assentamento (t_A), definido como o tempo necessário para se ter a resposta no interior de uma faixa percentual arbitrária do valor estacionário, no caso 1%.

4 Resultados e Discussão

Neste capítulo serão apresentados e discutidos os resultados dos testes e simulações, avaliando a capacidade do PID para inferência e a qualidade da mesma. Os resultados foram separados em estimativa do ganho e da constante de tempo.

4.1 Estudo da estimação do ganho

4.1.1 Estudo da sintonia

Analisou-se primeiro a resposta somente com o uso da ação proporcional. Verificou-se que, assim como numa malha de controle tradicional, somente essa ação não foi suficiente para obter a inferência correta. O que ocorre é um offset crescente, ilustrado na Figura 4.1 para diversos valores de K_c .

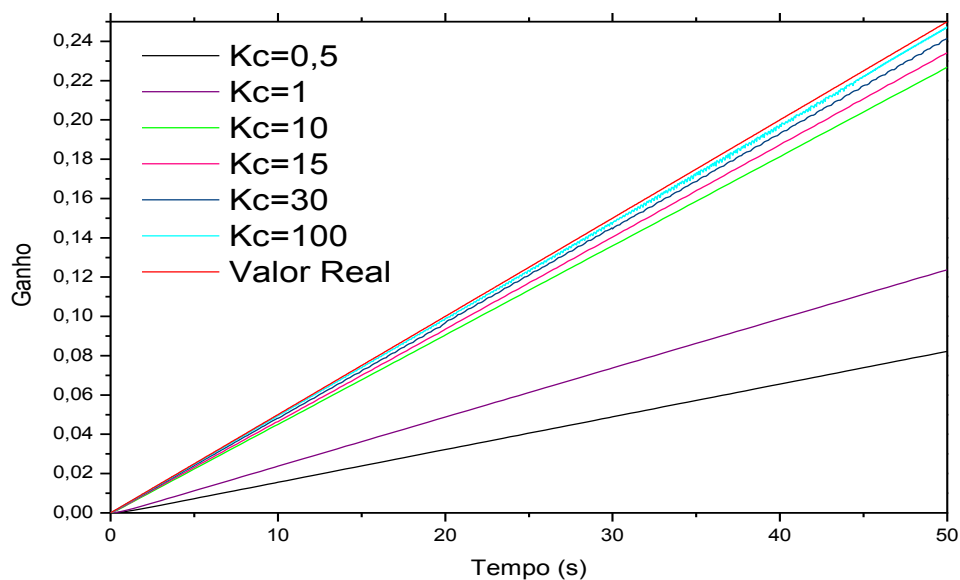


Figura 4.1: Estimativa do ganho para diferentes valores de K_c

Utilizando a ação integral esse offset quase se anula, conforme visto na Figura 4.2. Quanto maior essa ação, menor o offset e as integrais do erro, no entanto verificou-se que uma ação integral muito elevada (τ_i menores que 0,05) produz oscilação no início da resposta.

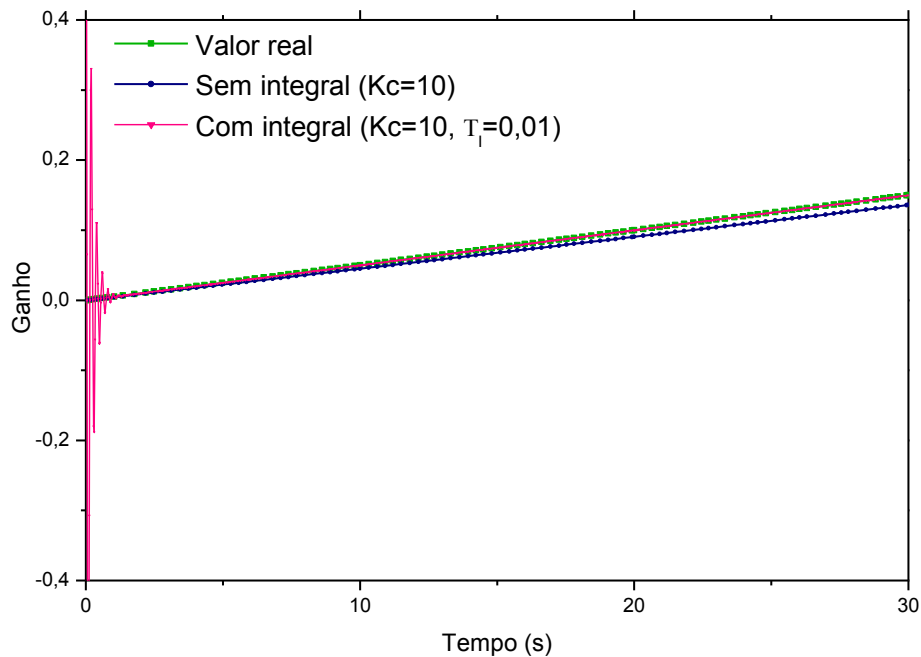


Figura 4.2: Estimativa do ganho com e sem a ação integral ($K_c=10$, $\tau_i=0,01$)

Com τ_i fixado em 0,01, a ação proporcional produziu resultados melhores para K_c maiores que 10, reduzindo offset, t_A e as integrais do erro. Valores de K_c menores que 1, além de aumentarem os critérios avaliados, geraram oscilação.

A Tabela 4.1 apresenta os parâmetros do PID e os valores obtidos para os critérios de desempenho avaliados, variando-se τ_i . A Tabela 4.2 mostra o mesmo, porém variando K_c . Não foi necessário utilizar a ação derivativa visto que com as ações proporcional e integral a inferência obtida foi correta.

Tabela 4.1: Comparativo da inferência do ganho crescente com o tempo a uma taxa de $0,005s^{-1}$ a diferentes τ_i com $K_c=10$

τ_i	Offset	t_A	IAE	ITAE	ISE
0,001	7,11E-15	-	25,06	1,26	9,78E+03
0,005	1,06E-04	-	25,16	2,56	9,78E+03
0,01	1,20E-03	-	25,35	3,61	9,79E+03
0,1	1,40E-03	0,72	29,11	4,09	9,82E+03
0,5	5,50E-03	3,27	28,00	16,68	9,90E+03
1	1,52E-02	0,22	20,99	25,40	1,00E+04
5	1,17E-01	26,39	99,24	439,40	1,07E+04
10	-1,23E-01	25,01	184,50	1314,00	1,16E+04
15	6,65E-01	40,35	271,10	2964,00	1,25E+04
100	não estabiliza	-	765,20	16930,00	2,13E+04

Tabela 4.2: Comparativo da inferência do ganho crescente com o tempo a uma taxa de $0,005s^{-1}$ a diferentes K_c com $\tau_i=0,01$

K_c	Offset	t_A	IAE	ITAE	ISE
0,005	4,00E-01	11,85	1414,00	2966,00	6,82E+05
0,05	1,85E-01	11,07	1035,00	1781,00	4,15E+05
0,5	8,23E-03	4,22	365,40	237,80	1,43E+05
1	1,25E-03	2,60	213,20	90,90	3,33E+04
10	1,20E-03	0,26	25,35	3,61	9,79E+03
15	1,26E-04	0,22	17,07	1,31	6,57E+03
30	7,07E-05	0,14	8,76	0,26	3,30E+03
50	4,61E-05	-	5,47	0,11	1,99E+03

Foi feita a sintonia para outras taxas de variação do parâmetro real com o tempo. Pela análise da Tabela 4.3, percebe-se que para o melhor ajuste, o K_c é inversamente proporcional à taxa de variação.

Tabela 4.3: Melhor ajuste obtido para diferentes taxas de variação do ganho

Taxa de variação $*10^3s^{-1}$	K_c	τ_i
0,1	200	0,01
5	30	0,01
200	0,1	0,05
800	0,05	0,05

4.1.2 Influência da taxa de variação do ganho

A Tabela 4.4 mostra a resposta a diferentes taxas de variação do ganho, mantendo-se constante o ajuste feito para taxa de $5 \cdot 10^{-3}s^{-1}$ ($K_c=30$ e $\tau_i=0,01$). Taxas de variação menores causam diminuição do offset e aumento das integrais IAE, ITAE e ISE.

Tabela 4.4: Comparativo da resposta a diferentes taxas de variação do ganho

Taxa de variação $*10^3s^{-1}$	Offset	IAE	ITAE	ISE
0,005	3,69E-13	1134,00	2,10E+03	4,63E+05
0,05	2,20E-13	513,10	4,58E+02	2,01E+05
0,5	3,00E-03	80,03	1,66E+01	3,12E+04
1	2,06E-13	41,45	6,44E+00	1,61E+04
5	7,07E-05	8,76	2,64E-01	3,30E+03
10	3,66E-05	4,66	9,49E-02	1,66E+03
20	1,86E-05	2,60	-1,66E-03	8,31E+02
100	-3,13E-05	0,61	-7,53E-04	1,66E+02
200	-1,81E-05	0,31	-4,52E-04	8,32E+01

4.1.3 Efeito de distúrbios

Foram aplicados degraus na entrada de controle, mantendo-se fixa a sintonia feita para uma entrada de 1 ($K_c=30$ e $\tau_i=0,01$). Até certo valor de degrau (20), a inferência foi

correta e os degraus aplicados na entrada não produziram grande mudança nos critérios avaliados, conforme pode ser visto na

Tabela 4.5. No entanto, para degraus maiores que 20, o offset apresentou oscilações periódicas. E distúrbios negativos na entrada instabilizaram a inferência. Ambos comportamentos são ilustrados na Figura 4.3.

Tabela 4.5: Comparativo do efeito de diferentes degraus na entrada da função, aplicados dos 10s até 50s

Entrada	Offset	IAE	ITAE	ISE
1 para 0,05	1,0510e-04	20,65	1,609	4028
1 para 0,1	7,3292e-05	20,64	1,523	4028
1 para 0,5	1,2431e-05	20,64	1,469	4028
1	4,2197e-05	20,65	1,549	4028
1 para 5	-7,9447e-04	20,64	1,415	4028
1 para 10	2,5710e-05	20,64	1,389	4028
1 para 20	-1,0947e-03	20,64	1,380	4028

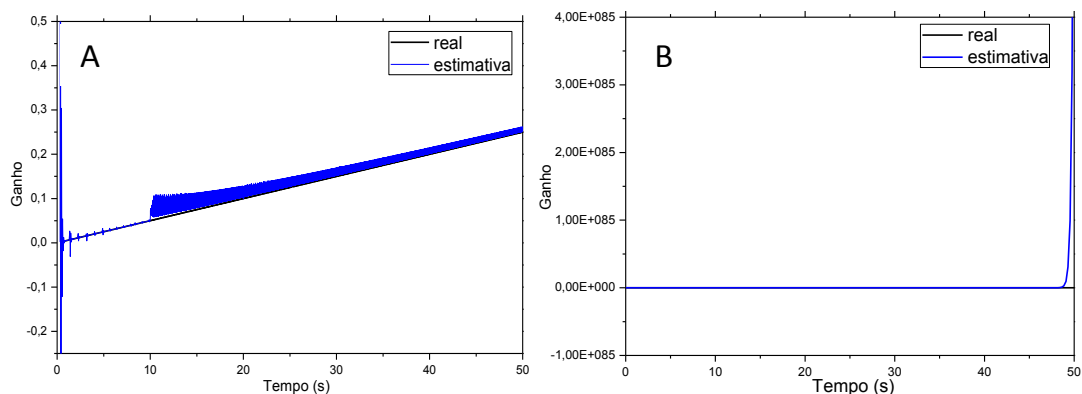


Figura 4.3: Degrau na entrada de 1 para 30 (A) e de 1 pra -0,01 (B) em 10s

4.1.4 Monitoração da saída x Monitoração do parâmetro

Foi feita uma análise para comparar o erro na saída do modelo com o erro da inferência do parâmetro, visto que em casos reais não se tem o valor real do mesmo para monitorar a qualidade da aproximação.

Verificou-se que o offset entre a inferência e valor real do ganho é superior ao offset entre as saídas da função transferência. O mesmo vale para as integrais do erro. A Tabela 4.6 faz a comparação das respostas.

Tabela 4.6: Comparação das respostas real e estimadas para parâmetro e saída com ganho crescente com o tempo a uma taxa de $0,005s^{-1}$ e $K_c=10$

τ_i	Saída				Ganho			
	Offset	IAE	ITAE	ISE	Offset	IAE	ITAE	ISE
0,001	9,85E-08	5,67E-04	1,49E-04	4,89E-06	7,11E-15	25,06	1,26	9,78E+03
0,005	5,30E-07	1,30E-03	6,79E-04	2,45E-05	1,06E-04	25,16	2,56	9,78E+03
0,01	1,00E-06	1,90E-03	1,33E-03	4,89E-05	1,20E-03	25,35	3,61	9,79E+03
0,1	1,01E-05	1,05E-02	1,35E-02	4,90E-04	1,40E-03	29,11	4,09	9,82E+03
0,5	5,05E-05	5,21E-02	8,71E-02	2,45E-03	5,50E-03	28,00	16,68	9,90E+03
1	1,00E-04	1,04E-01	2,21E-01	4,89E-03	1,52E-02	20,99	25,40	1,00E+04
5	4,93E-04	4,96E-01	2,67E+00	2,43E-02	1,17E-01	99,24	439,40	1,07E+04
10	2,69E-04	9,54E-01	8,65E+00	4,81E-02	-1,23E-01	184,50	1314,00	1,16E+04

4.2 Estudo da estimação da dinâmica (constante de tempo dominante)

4.2.1 Estudo da sintonia

Os resultados aqui apresentados foram todos obtidos com a entrada e o ganho da função transferência fixados em 1 e para τ igual a 50. Mantendo-se K_c constante, vários valores de τ_i foram testados. A Figura 4.4 apresenta o valor previsto pelo PID para o parâmetro.




Figura 4.4: Estimativa da constante de tempo para diferentes valores de τ_i , com $K_c=10$

O offset diminuiu com o aumento da ação integral (redução de τ_i), enquanto os valores de IAE, ITAE e ISE aumentaram. Esse aumento pode ser explicado pelo crescimento da oscilação junto com a ação integral, conforme mostra a Figura 4.4. O

aumento da oscilação produziu um aumento do tempo de assentamento. A Tabela 4.7 apresenta os valores encontrados para os critérios avaliados.

Tabela 4.7: Critérios de desempenho para diferentes τ_i

τ_i	Offset	t_A	IAE	ITAE	ISE
0,001	4,12E-02	90	1,39E+03	1,80E+04	1,04E+05
0,005	-3,26E-02	95	1,31E+03	1,62E+04	9,51E+04
0,05	2,76E-02	72	1,21E+03	1,54E+04	7,66E+04
0,1	8,71E-03	75	1,16E+03	1,53E+04	6,69E+04
0,5	1,89E-02	75	9,63E+02	1,44E+04	3,91E+04
1	-2,44E-02	80	8,50E+02	1,37E+04	2,75E+04
5	-1,35E-02	77	5,66E+02	1,05E+04	1,01E+04
10	-2,58E-02	84	4,72E+02	8,43E+03	7,72E+03
15	2,95E-02	66,4	4,38E+02	7,39E+03	7,39E+03
30	-1,86E-01	75	4,17E+02	6,21E+03	7,90E+03
50	8,67E-05	57	4,30E+02	4,44E+03	8,74E+03
75	6,26E-01	>100	5,50E+02	1,01E+04	9,56E+03
100	1,22E+00	>100	6,26E+02	1,40E+04	1,02E+04

Da mesma forma, τ_i foi fixado ($\tau_i = 0,1$) e variou-se K_c . Quanto maior o K_c , menores foram o offset e integrais do erro. Para K_c menores que 5, 100s não foram suficientes para chegar numa resposta estável. Os resultados desse teste estão na Tabela 4.8.

Tabela 4.8: Critérios de desempenho para diferentes K_c

K_c	Offset	t_A	IAE	ITAE	ISE
5	9,98E-01	98	1,73E+03	3,34E+04	1,02E+05
10	-2,45E-02	80	1,16E+03	1,53E+04	6,69E+04
15	5,29E-04	70	8,88E+02	9,19E+03	5,22E+04
30	4,26E-08	40	5,43E+02	3,66E+03	2,87E+04
50	-2,05E-12	28	3,66E+02	1,77E+03	1,79E+04
75	-2,90E-12	20	2,61E+02	9,67E+02	1,19E+04
100	0,00E+00	17	2,04E+02	6,19E+02	8,79E+03

Como a inferência apresenta bastante oscilação, foi investigado se a ação derivativa poderia reduzir esse comportamento.

A Figura 4.5 apresenta as inferências sem e com a ação derivativa, mostrando a redução da oscilação para o último caso. Quanto maiores os valores de τ_D , menor a oscilação, sendo que para valores maiores que 50, a melhoria frente aos anteriores não é mais significativa. Esses comportamentos foram verificados para para $\tau_i=0,1$ e $K_c=50$.




Figura 4.5: Estimativa da constante de tempo com e sem a ação derivativa ($K_c=50$, $\tau_i=0,1$, $\tau_D=15$)

Outro efeito da ação derivativa foi o aumento do offset (ver Tabela 4.9). Desta forma, escolheu-se o melhor ajuste ($K_c=50$, $\tau_i=1$) sem esta ação, priorizando a exatidão do parâmetro estimado e não a performance.

Tabela 4.9: Critérios de desempenho com e sem a ação derivativa ($K_c=50$, $\tau_i=0,1$, $\tau_D=15$)

Derivativo	Offset	t_s	IAE	ITAE	ISE
Sem	-2,05E-12	28	3,66E+02	1,77E+03	1,79E+04
Com	-1,25E-03	7,5	4,01E+01	7,31E+01	5,27E+02

A Tabela 4.10 mostra que o ajuste realizado foi eficiente para estimar constantes de tempo diferentes. Sendo que para valores inferiores a 0,5 a estimação se mostrou instável e superiores a 100, os 100s não foram suficientes para estabilização.

Tabela 4.10: Critérios de desempenho para constantes de tempo diferentes

τ	Offset	t_A	IAE	ITAE	ISE
0,5	1,92E-06	1	1,92E-03	2,94E-03	1,04E-04
1	0	0	0,00E+00	0,00E+00	0,00E+00
20	0	5	1,70E+01	3,21E+01	9,20E+01
30	0	10	6,09E+01	2,00E+02	6,34E+02
40	-1,28E-13	15	1,40E+02	6,73E+02	2,40E+03
50	-5,04E-13	30	2,61E+02	1,64E+03	6,43E+03
60	-1,39E-10	30	4,24E+02	3,29E+03	1,40E+04
70	1,38E-07	35	6,32E+02	5,81E+03	2,62E+04
80	-4,90E-06	40	8,83E+02	9,40E+03	4,46E+04
100	1,19E-03	54	1,52E+03	2,05E+04	1,05E+05

4.2.2 Efeitos de distúrbios

Foram aplicados distúrbios na entrada da função transferência e na própria constante de tempo a ser estimada.

Distúrbios na entrada

O ajuste foi eficaz e a inferência correta para degraus na entrada de 1 até 1000 e de 1 até 0,001. Quando a entrada foi de um valor positivo para um negativo o sistema instabilizou. A estimativa do PID para os dois casos é apresentada na Figura 4.6.




Figura 4.6: Inferência com degraus na entrada de 1 para 0,001 (A) e 1 para -5 (B) aplicados em 50s. $\tau_1=1$, $K_c=50$

Distúrbios na constante de tempo

O PID conseguiu identificar corretamente o valor da constante de tempo na maioria dos casos testados com τ variando ao longo do tempo. A simulação começou com a constante em 50 e, em todos os degraus positivos, obteve-se estimativas corretas, mesmo que com um tempo maior que 100s necessário. Degráus para baixo instabilizaram para valores menores que 5 (Figura 4.7).

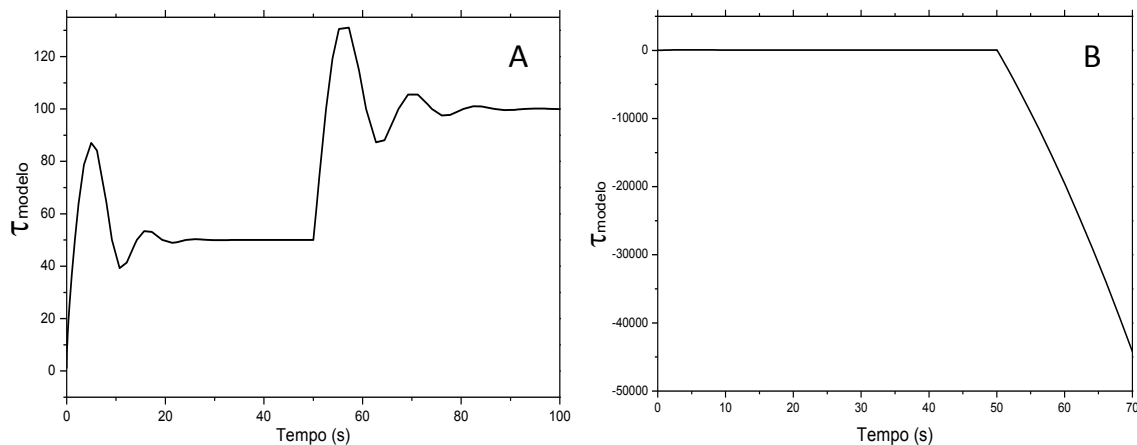


Figura 4.7: Inferências com degrau na constante de tempo de 50 para 100 (A) e 50 para 1 (B) aplicados em 50s. $\tau_1=1$, $K_c=50$

4.2.3 Monitoração da saída x Monitoração do parâmetro

Os resultados da Tabela 4.11 mostram que, assim como para o ganho, o valor dos critérios avaliados é menor para a saída da função transferência do que para o parâmetro. Percebeu-se também que ambos estão relacionados, ou seja, se o erro na saída diminui ou aumenta o mesmo ocorre para o parâmetro.

Tabela 4.11: Comparação das respostas real e estimadas para parâmetro e saída com $\tau=50$ e $\tau_i=0,1$

Kc	Saída				Tau			
	Offset	IAE	ITAE	ISE	Offset	IAE	ITAE	ISE
5	1,28E-02	1,86E+01	4,59E+02	8,00E+00	9,98E-01	1,73E+03	3,34E+04	1,02E+05
10	-3,89E-04	8,21E+00	1,37E+02	2,33E+00	-2,45E-02	1,16E+03	1,53E+04	6,69E+04
15	-1,11E-05	4,96E+00	6,39E+01	1,10E+00	5,29E-04	8,88E+02	9,19E+03	5,22E+04
30	-3,61E-10	2,03E+00	1,65E+01	2,95E-01	4,26E-08	5,43E+02	3,66E+03	2,87E+04
50	-2,13E-14	1,03E+00	5,84E+00	1,08E-01	-2,05E-12	3,66E+02	1,77E+03	1,79E+04
75	1,42E-14	5,91E-01	2,49E+00	4,81E-02	-2,90E-12	2,61E+02	9,67E+02	1,19E+04
100	0,00E+00	3,96E-01	1,35E+00	2,68E-02	0,00E+00	2,04E+02	6,19E+02	8,79E+03

5 Teste em uma Planta Real

Neste capítulo é apresentada a aplicação da estrutura PID em estudo num sistema real, no caso a Planta Laboratorial de Seis Tanques Esféricos. São descritos a planta, os procedimentos utilizados para o teste e os resultados obtidos.

5.1 Descrição da Planta de Seis Tanques Esféricos

A Planta Laboratorial de Seis Tanques Esféricos está localizada no Departamento de Engenharia Química (DEQUI) da UFRGS.

É um sistema formado por seis tanques de geometria aproximadamente esférica, com diâmetro de aproximadamente 22,5cm, os quais estão interligados entre si por tubulações e dispostos em dois ramos de três tanques, conforme Figura 5.1. Abaixo destes tanques, encontra-se um reservatório de água com quatro pequenas bombas submersas. Estas bombas foram numeradas de acordo com o tanque a qual estão associadas. As bombas B1 e B2 fornecem a vazão de alimentação aos tanques superiores, H1 e H2, enquanto a vazão de alimentação dos tanques intermediários, H3 e H4, é dada por outras duas bombas, B3 e B4 respectivamente. As vazões das quatro bombas são modificadas através da variação da tensão de alimentação das mesmas e os níveis dos seis tanques são medidos através de células de carga, as quais servem também de sustentação para os tanques. Existem também válvulas que não aparecem na Figura 5.1, que podem ser usadas para controlar a vazão de saída ou mesmo desviar o fluxo entre os tanques.



Figura 5.1: Planta Laboratorial de Seis Tanques Esféricos

Para os testes foi utilizado o tanque superior direito (H2), cuja vazão é fornecida pela bomba B2.

5.2 Modelagem e implementação do PID junto à planta

O modelo do tanque é dado pela Equação 5.1, onde h é o nível do tanque, F_{in} a vazão de entrada, CD o coeficiente de descarga e D o diâmetro do tanque ($D=22,5\text{cm}$).

$$\frac{dh}{dt} = \frac{F_{in} - CD \sqrt{h}}{(D-h)\pi h} \quad (5.1)$$

Por sua vez, o coeficiente de descarga (CD) engloba o coeficiente de descarga propriamente dito (C_d) e demais termos da Equação 5.2.

$$CD = C_d A_0 \sqrt{2g} \quad (5.2)$$

Esse modelo foi implementado no MATLAB através de uma *S-Function*, cuja rotina é apresentada no Apêndice B. As entradas do modelo são a vazão de alimentação do tanque e o coeficiente de descarga. A saída é o nível do tanque.

O modelo é executado em paralelo com a planta. A entrada de ambos é a vazão de alimentação e o nível medido na planta é comparado com a saída do modelo. Essa diferença é a entrada do PID, enquanto a inferência é dada pela saída do mesmo.

A Figura 5.2 mostra como o sistema foi implementado em diagrama de blocos.

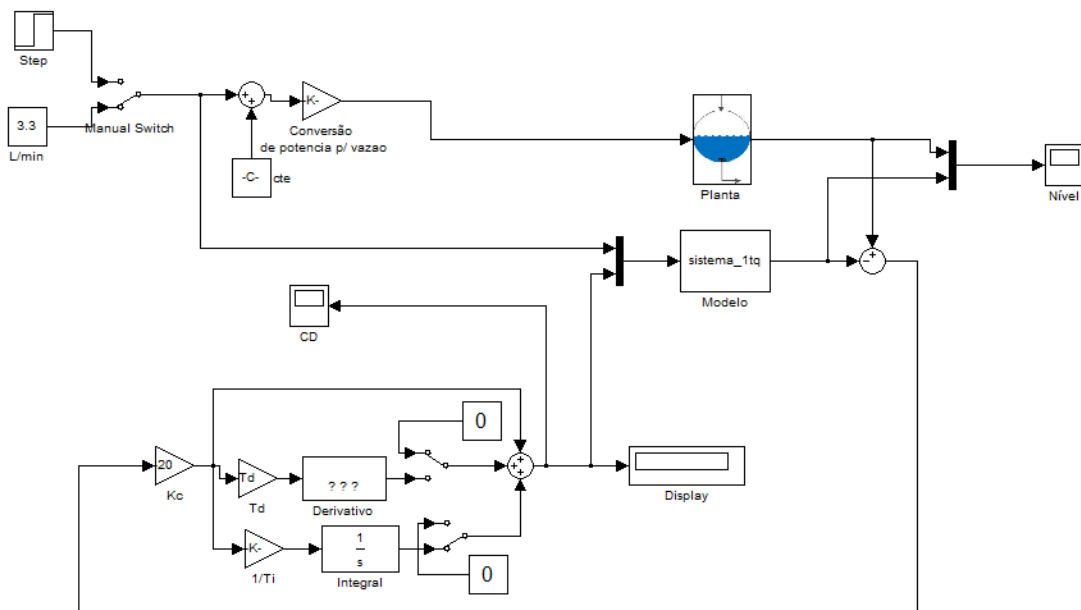


Figura 5.2: Sistema implementado em *Simulink* para estimativa do CD.

5.3 Ajuste dos parâmetros

Para ajuste dos parâmetros do PID testes preliminares foram feitos off-line, ou seja, somente com o modelo, arbitrando-se o valor de CD . O melhor ajuste foi $K_c = -15$ e $\tau_i = 10$. Com o valor de K_c positivo a estimação é instável conforme ilustrado na Figura 5.3.

O valor negativo do ganho pode ser explicado numa analogia com a ação direta ou inversa do controlador numa malha de controle. No caso do modelo, a variável de entrada do PID é o nível, que diminui quando o CD , saída do PID, aumenta. Com o ganho

negativo, o PID se torna capaz de reproduzir esse comportamento, aumentando o valor de CD quando o nível diminui e vice-versa.

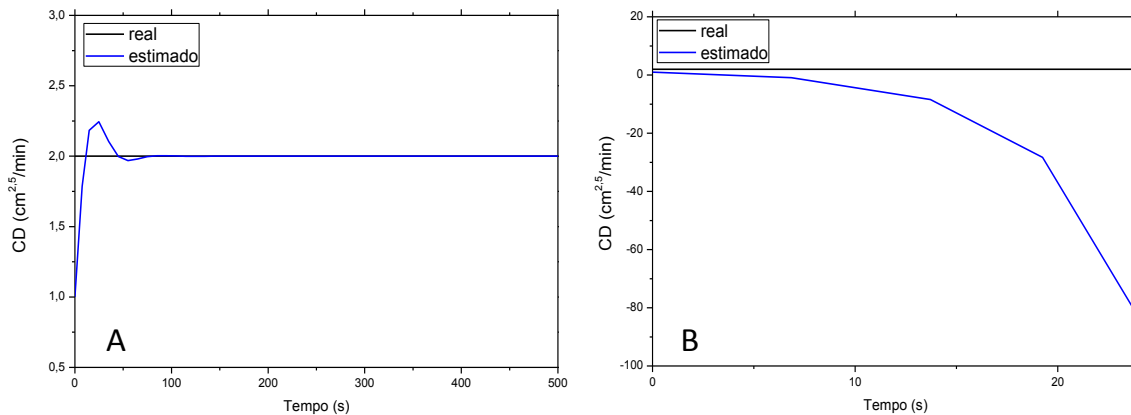


Figura 5.3: Inferência para o CD com $K_c=-15$, $\tau_i=10$ (A) e $K_c=15$, $\tau_i=10$ (B)

5.4 Resultados do teste na planta

Para realização desse teste, assumiu-se que uma resposta semelhante para o nível medido na planta e o previsto pelo modelo implica na inferência correta do parâmetro.

O ajuste para correta inferência na planta foi diferente daquele encontrado nas simulações. As condições iniciais do teste foram com $K_c=-15$, $\tau_i=10$. Para esses valores a inferência instabilizou. Assim, aumentou-se o valor de τ_i para reduzir a ação integral, chegando no valor de $\tau_i=1500$.

Para reduzir a diferença no nível entre o real e o do modelo, em 190s alterou-se K_c para -20. A Figura 5.4 mostra como ficou a resposta do nível com essa ação e o impacto na inferência do parâmetro. Testou-se também os efeitos da ação derivativa, que gerou aumento de ruído na inferência do parâmetro, o que também pode ser visto na Figura 5.4.




Figura 5.4: Efeitos dos parâmetros do PID na inferência do parâmetro e na resposta do nível

Outro teste foi feito alterando a abertura da válvula de saída do tanque. Os resultados desse teste são apresentados nas Figuras 5.5, 5.6 e 5.7. Conforme esperado, ao fechar a

válvula, em 280s, reduzindo a vazão de saída, o CD diminuiu. Quando a válvula foi totalmente aberta novamente, no tempo de 670s, o CD volta a aumentar.

Entre os 400 e 670 segundos as variações no CD se devem as mudanças feitas na vazão de alimentação para manter o nível na faixa de trabalho. Quando a vazão foi reduzida, em 390s, o turbilhonamento que acontecia no líquido dentro do tanque para a vazão de 3,5L/min diminuiu, aumentando a pressão exercida pela coluna de líquido, e por consequência o CD. Quando a vazão aumentou novamente em 550s, a intensidade do turbilhonamento também cresceu e o CD reduziu novamente.

Outra possível explicação é que existem erros de calibração nos instrumentos, de modo que o CD estimado acaba atuando como um fator global de ajuste do modelo, capturando quaisquer erros que possam existir entre este e a planta.




Figura 5.5: Nível medido na planta e previsto pelo modelo




Figura 5.6: CD estimado pelo PID

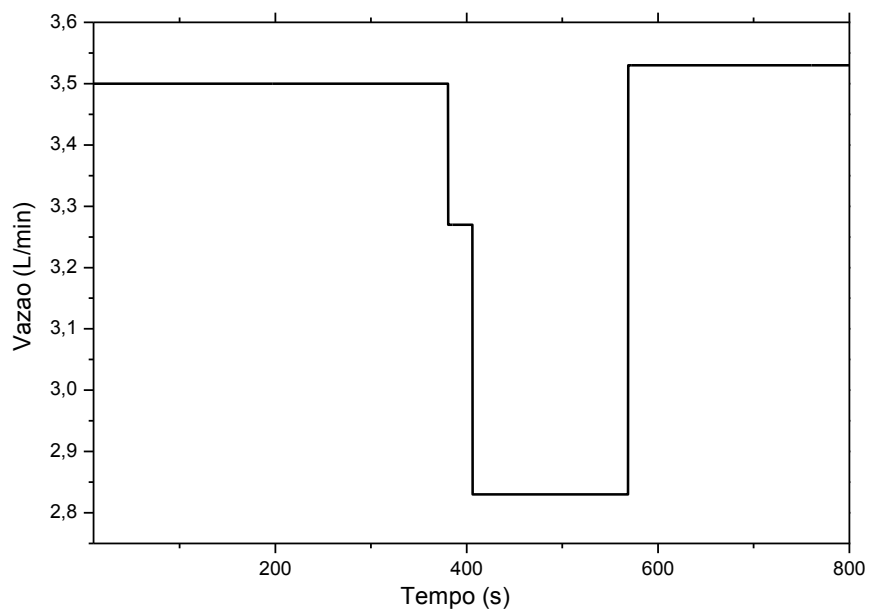


Figura 5.7: Vazão de alimentação fornecida à planta

6 Conclusões e Trabalhos Futuros

Neste estudo uma estrutura PI/PID foi implementada em MATLAB e avaliada para inferência de parâmetros de uma função de transferência. Esses parâmetros foram o ganho e a constante de tempo. Para ambos os casos, o PID foi capaz de identificar corretamente o valor do parâmetro nas situações testadas, desde que com sintonia adequada. Além disso, essa mesma estrutura se mostrou eficiente na estimativa, ainda que com distúrbios na entrada da função. A exceção foi para os distúrbios que consistem em um valor negativo na entrada, onde a inferência instabiliza.

Quanto aos efeitos de cada ação (proporcional, integral e derivativa) verificou-se que são equivalentes aos efeitos de quando o PID é usado numa malha de controle. Situações que ficaram claramente visíveis foram: aumento da ação proporcional aumenta a velocidade da resposta e, se a ação for muito grande, a resposta apresenta oscilações; quanto maior a ação integral, maior a oscilação; a ação derivativa diminui as oscilações produzidas pela ação integral.

A estrutura também foi eficaz para estimação do coeficiente de descarga do modelo de um tanque na Planta Laboratorial de Seis Tanques Esféricos do DEQUI, em tempo real. Apesar de ser um sistema simples, o sucesso nessa aplicação indica potencial para o uso do PID para inferência em sistemas reais.

Provada a capacidade da estrutura para inferências, trabalhos futuros podem focar no desenvolvimento de métodos de ajuste para o PID como estimador, facilitando o uso para aqueles não familiarizados com o mesmo. Também pode ser averiguado se os resultados aqui obtidos para inferência de propriedades podem ser estendidos para outros tipos de distúrbios, parâmetros, dinâmicas e ainda outros sistemas reais mais complexos. Indo além, pode-se verificar a possibilidade do uso do PID para inferência de mais de um parâmetro dentro do modelo.

7 Referências

CHOI, Y. PID state estimator for Lagrangian systems. **Control Theory & Applications, IET**, v. 1, n. 4, p. 937-945, 2007. ISSN 1751-8644.

DAUM, F. Nonlinear filters: beyond the Kalman filter. **Aerospace and Electronic Systems Magazine, IEEE**, v. 20, n. 8, p. 57-69, 2005. ISSN 0885-8985.

FORTUNA, L.; GRAZIANI, S.; XIBILIA, M. G. Soft sensors for product quality monitoring in debutanizer distillation columns. **Control Engineering Practice**, v. 13, n. 4, p. 499-508, 2005. ISSN 0967-0661.

GALICIA, H. J.; HE, Q. P.; WANG, J. A reduced order soft sensor approach and its application to a continuous digester. **Journal of Process Control**, v. 21, n. 4, p. 489-500, 2011. ISSN 0959-1524.

JARULLAH, A. T.; MUJTABA, I. M.; WOOD, A. S. Kinetic parameter estimation and simulation of trickle-bed reactor for hydrodesulfurization of crude oil. **Chemical Engineering Science**, v. 66, n. 5, p. 859-871, 2011. ISSN 0009-2509.

JIA, R.-D. et al. Soft-sensor for copper extraction process in cobalt hydrometallurgy based on adaptive hybrid model. **Chemical Engineering Research and Design**, v. 89, n. 6, p. 722-728, 2011. ISSN 0263-8762.

KADLEC, P.; GABRYS, B.; STRANDT, S. Data-driven Soft Sensors in the process industry. **Computers & Chemical Engineering**, v. 33, n. 4, p. 795-814, 2009. ISSN 0098-1354.

KADLEC, P.; GRBIĆ, R.; GABRYS, B. Review of adaptation mechanisms for data-driven soft sensors. **Computers & Chemical Engineering**, v. 35, n. 1, p. 1-24, 2011. ISSN 0098-1354.

KAILATH, T. *Linear Systems* (Prentice-Hall Information and System Science Series), 1979.

KANDEPU, R.; FOSS, B.; IMSLAND, L. Applying the unscented Kalman filter for nonlinear state estimation. **Journal of Process Control**, v. 18, n. 7-8, p. 753-768, 2008/9// 2008. ISSN 0959-1524.

KANO, M.; FUJIWARA, K. Virtual sensing technology in process industries: Trends and challenges revealed by recent industrial applications. **Journal of Chemical Engineering of Japan**, v. 46, n. 1, p. 1-17, 2013.

KUEN, H. Y.; MJALLI, F. S.; KOON, Y. H. Recursive Least Squares-Based Adaptive Control of a Biodiesel Transesterification Reactor. **Industrial & Engineering**

Chemistry Research, v. 49, n. 22, p. 11434-11442, 2014/10/20 2010. ISSN 0888-5885.

LEE, C.; CHOI, S. W.; LEE, I.-B. Sensor fault identification based on time-lagged PCA in dynamic processes. **Chemometrics and Intelligent Laboratory Systems**, v. 70, n. 2, p. 165-178, 2004. ISSN 0169-7439.

LEE, J. H.; LEE, J. M. Progress and Challenges in Control of Chemical Processes. **Annual Review of Chemical and Biomolecular Engineering**, v. 5, n. 1, p. 383-404, 2014/10/20 2014. ISSN 1947-5438.

LI, W. et al. Recursive PCA for adaptive process monitoring. **Journal of Process Control**, v. 10, n. 5, p. 471-486, 2000. ISSN 0959-1524.

MARLIN, T. E. *Process Control*. New York: McGraw-Hill (1995).

RAWLINGS, J. B.; BAKSHI, B. R. Particle filtering and moving horizon estimation. **Computers & Chemical Engineering**, v. 30, n. 10-12, p. 1529-1541, 2006. ISSN 0098-1354.

SOROUSH, M. State and parameter estimations and their applications in process control. **Computers & Chemical Engineering**, v. 23, n. 2, p. 229-245, 1998. ISSN 0098-1354.

WANG, X.; KRUGER, U.; IRWIN, G. W. Process Monitoring Approach Using Fast Moving Window PCA. **Industrial & Engineering Chemistry Research**, v. 44, n. 15, p. 5691-5702, 2014/12/10 2005. ISSN 0888-5885.

WARNE, K. et al. Statistical and computational intelligence techniques for inferential model development: a comparative evaluation and a novel proposition for fusion. **Engineering Applications of Artificial Intelligence**, v. 17, n. 8, p. 871-885, 2004. ISSN 0952-1976.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. PLS-regression: a basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n. 2, p. 109-130, 2001. ISSN 0169-7439.

8 Apêndice

Apêndice A – Modelo para uma função transferência de primeira ordem

```

function [sys, x0] = sistema_lin(t,x,u,flag,xs)

% SISTEMA_lin. Sistema Linear.
%

switch flag,

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % Initialization %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%

    case 0,
        [sys,x0,str,ts] = mdlInitializeSizes(t,x,u,xs);

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % Derivatives %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    case 1,
        sys = mdlDerivatives(t,x,u);

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % Update %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%

    case 2,
        sys = [];

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % Outputs %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    case 3,

        sys = mdlOutputs(t,x);

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % GetTimeOfNextVarHit %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    case 4,
        sys = [];

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % Terminate %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    case 9,

        sys = mdlTerminate(t,x,u);

    %%%%%%%%%%%%%%%%%%%%%%%%%%%
    % Unexpected flags %
    %%%%%%%%%%%%%%%%%%%%%%%%%%%

otherwise

    error(['Unhandled flag = ',num2str(flag)]);

end
%
```

```

%=====
%=====
% mdlInitializeSizes
% Return the sizes, initial conditions, and sample times for the S-
function.
%=====
%=====
%
function [sys,x0,str,ts] = mdlInitializeSizes(t,x,u,xs)

sizes = simsizes;

sizes.NumContStates = 1;
sizes.NumDiscStates = 0;
sizes.NumOutputs = 1;
sizes.NumInputs = 2;
sizes.DirFeedthrough = 0;
sizes.NumSampleTimes = 1; % at least one sample time is needed

sys = simsizes(sizes); sys = [1 0 1 2 0 0];
%
% initialize the initial conditions
%
x0 = xs;

% str is always an empty matrix
%
str = [];
%
% initialize the array of sample times
%
ts = [0 0];
% end mdlInitializeSizes

%
%=====
%=====
% mdlDerivatives
% Return the derivatives for the continuous states.
%=====
%=====
%
function sys = mdlDerivatives(t,x,u)

% System parameters
K = 1;
tau = u(2); %

sys(1) = -1/tau*x + K*u(1);

% end mdlDerivatives

%
%=====
%=====
% mdlOutputs
% Return the block outputs.
%=====
%=====
%
function sys = mdlOutputs(t,x)

% Output

```



```
sys = x(1);

% end mdlOutputs

%
%=====
%=====
% mdlTerminate
% Perform any end of simulation tasks.
%=====
%=====
%
function sys = mdlTerminate(t,x,u)

sys = [];

% end mdlTerminate
```



```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Terminate %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
case 9,

    sys = mdlTerminate(t,x,u);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% Unexpected flags %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

otherwise

    error(['Unhandled flag = ',num2str(flag)]);

end

%
%=====
%=====
% mdlInitializeSizes
% Return the sizes, initial conditions, and sample times for the S-
% function.
%=====
%=====
%
function [sys,x0,str,ts] = mdlInitializeSizes(t,x,u,xs)

sizes = simsizes;

sizes.NumContStates = 1;
sizes.NumDiscStates = 0;
sizes.NumOutputs = 1;
sizes.NumInputs = 2;
sizes.DirFeedthrough = 0;
sizes.NumSampleTimes = 1; % at least one sample time is needed

sys = simsizes(sizes); sys = [1 0 1 2 0 0];
%
% initialize the initial conditions
%
x0 = xs;

% str is always an empty matrix
%
str = [];
%
% initialize the array of sample times
%
ts = [0 0];
% end mdlInitializeSizes

%
%=====
%=====
% mdlDerivatives
% Return the derivatives for the continuous states.
%=====
%=====
%
function sys = mdlDerivatives(t,x,u)

```

```
% System parameters
D = 22,5; %cm
CD = u(2); %;0.9*183; %cm^2.5/min

if x > 1e-3 | x < D - 1e-3
    sys(1) = (u(1) - CD*sqrt(x))/pi/x/(D - x);
else
    sys(1) = 0;
end

% end mdlDerivatives

%=====
%====
% mdlOutputs
% Return the block outputs.
%=====
%====
%
function sys = mdlOutputs(t,x)

% Output
sys = x(1);

% end mdlOutputs

%
%=====
%====
% mdlTerminate
% Perform any end of simulation tasks.
%=====
%====
%
function sys = mdlTerminate(t,x,u)

sys = [];

% end mdlTerminate
```