



**APRIMORAMENTO DO DESEMPENHO DO CONTROLADOR PREDITIVO
MULTIVARIÁVEL APLICADO EM COLUNA DEPROPANIZADORA
UTILIZANDO FILTRO DE KALMAN**

Cássio Ferreira Gomes

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Processos – Mestrado Profissional, PPGEP/ITEC, da Universidade Federal do Pará, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia de Processos.

Orientadores: Emanuel Negrão Macedo

Oscar Alberto Zanabria Sotomayor

Belém

Maio de 2019

**APRIMORAMENTO DO DESEMPENHO DO CONTROLADOR PREDITIVO
MULTIVARIÁVEL APLICADO EM COLUNA DEPROPANIZADORA
UTILIZANDO FILTRO DE KALMAN**

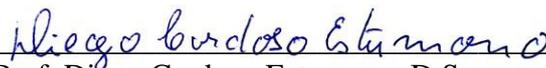
Cássio Ferreira Gomes

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA PROCESSOS – MESTRADO PROFISSIONAL (PPGEP/ITEC) DA UNIVERSIDADE FEDERAL DO PARÁ COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA DE PROCESSOS.

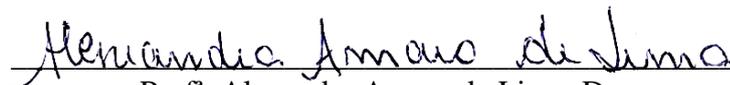
Examinada por:



Prof. Emanuel Negrão Macedo, D.Sc.
(PPGEP/ITEC/UFPA - Orientador)



Prof. Diogo Cardoso Estumano, D.Sc.
(PPGEP/ITEC/UFPA - Membro)



Prof^a. Alexandra Amaro de Lima, Dra.
(UNIP – Membro)

BELÉM, PA - BRASIL

MAIO DE 2019

**Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema de Bibliotecas da UFPA**

Gomes, Cássio Ferreira, 1983-
Aprimoramento do desempenho do controlador preditivo
multivariável aplicado em coluna depropanizadora utilizando
filtro de Kalman. - 2019.

Orientadores: Emanuel Negrão Macedo
Oscar Alberto Zanabria Sotomayor

Dissertação (Mestrado Profissional) - Universidade
Federal do Pará. Instituto de Tecnologia. Programa de Pós-
Graduação em Engenharia de Processos, 2019.

1. Controladores programáveis 2. Kalman, Filtragem de 3.
Controle de processo- Simulação por computador I. Título

CDD 22.ed.660.284245

Dedico este trabalho primeiramente a Deus, minha esposa Camila, meu filho Lucas Gabriel, meus pais Sebastião e Natividade e minha irmã Juliana.

AGRADECIMENTOS

A Deus por toda sabedoria e princípios seguidos.

Ao meu orientador Professor Dr. Emanuel Negrão e coorientador Professor Dr. Oscar Sotomayor, pelo acompanhamento durante as pesquisas experimentais e pela assistência na elaboração desta dissertação.

Aos professores e colegas do PPGEP.

Ao meu amigo e professor do IFS (Instituto Federal de Sergipe), Prof. Rodrigo Ribeiro, que sempre se mostrou prestativo em momentos em que tive dúvidas durante minhas simulações.

À UFS por todo conhecimento que adquiri lá durante toda minha graduação dando-me suporte a estar neste mestrado.

“Meus filhos terão computadores, sim, mas antes terão livros. Sem livros, sem leitura, os nossos filhos serão incapazes de escrever - inclusive a sua própria história.”

(Bill Gates)

Resumo da Dissertação apresentada ao PPGEP/UFPA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Processos (M. Eng.)

**APRIMORAMENTO DO DESEMPENHO DO CONTROLADOR PREDITIVO
MULTIVARIÁVEL APLICADO EM COLUNA DEPROPANIZADORA
UTILIZANDO FILTRO DE KALMAN**

Cássio Ferreira Gomes

Maio/2019

Orientadores: Emanuel Negrão Macedo

Oscar Alberto Zanabria Sotomayor

Área de Concentração: Engenharia de Processos

O aumento da eficiência dos processos industriais tem sido cada vez necessário nos dias atuais, em virtude da alta competitividade de mercado. Neste contexto, técnicas que buscam aumentar a eficiência no desempenho dos sistemas de controle das plantas industriais, minimizando custos e maximizando a qualidade do produto, a exemplo da utilização de Filtro de Kalman em variáveis de processo que realimentam os sistemas de controle, tem relevância significativa. Filtro de Kalman é uma técnica de estimação de parâmetros que permite, para sistemas lineares, a redução de ruídos e incertezas que estão submetidas as variáveis de processo. A sua ampla utilização se justifica, principalmente, devido ao fato de que as variáveis (informações) que são obtidas através do processo, através de instrumentos físicos e rotinas de medição, apresentam precisão finita e estão naturalmente corrompidas por erros (aleatórios ou grosseiros). Estas variáveis ao serem introduzidas no sistema de controle, sem a utilização do Filtro de Kalman, carregam todo sinal de ruído, reduzindo o desempenho do sistema de controle. O principal objetivo deste trabalho é apresentar os resultados da implementação de Filtro de Kalman no processo industrial, coluna depropanizadora, controlada através de Controlador Preditivo, com base em dados reais, de forma a melhorar o desempenho do controle e eficiência energética deste processo. Os estudos de simulação são realizados na plataforma MATLAB / SIMULINK.

Abstract of Dissertation presented to PPGE/UFPA as a partial fulfillment of the requirements for the degree of Master in Process Engineering (M. Eng.)

**IMPROVEMENT OF THE PERFORMANCE OF THE MULTIVARIATE
PREDICTIVE CONTROLLER APPLIED IN THE DEPROPANE COLUMN
USING KALMAN FILTER**

Cássio Ferreira Gomes

May/2019

Advisors: Emanuel Negrão Macedo

Oscar Alberto Zanabria Sotomayor

Research Area: Process Engineering

The increase in the efficiency of industrial processes has been necessary in the present day, due to the high market competitiveness. In this context, techniques that seek to increase the performance efficiency of industrial plant control systems, minimizing costs and maximizing product quality, such as the use of Kalman Filter in process variables that feed control systems, has significant relevance. Kalman filter is a parameter estimation technique that allows, for linear systems, the reduction of noise and uncertainties that are subject to process variables. Its wide use is mainly due to the fact that the variables (information) that are obtained through the process, through physical instruments and measurement routines, have finite precision and are naturally corrupted by errors (random or coarse). These variables, when introduced into the control system, without the use of the Kalman Filter, carry all noise signals, reducing the performance of the control system. The aim of this work is to present the results of the Kalman Filter implementation in the industrial process, a propane generator column, controlled through a Predictive Controller, based on real data, in order to improve control performance and energy efficiency of this process. Simulation studies are performed on the MATLAB / SIMULINK platform.

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO.....	1
1.1 - MOTIVAÇÃO.....	1
1.2 - JUSTIFICATIVA DA PROPOSTA DE ESTUDO.....	2
1.3 - OBJETIVOS.....	2
1.3.1 - Objetivo geral.....	2
1.3.2 - Objetivos específicos.....	3
1.4 - CONTRIBUIÇÕES DA DISSERTAÇÃO.....	3
1.5 - DELIMITAÇÃO.....	3
1.6 - ORGANIZAÇÃO DO TRABALHO.....	3
CAPÍTULO 2 – REVISÃO DA LITERATURA.....	5
2.1 - CONTROLE PREDITIVO MULTIVARIÁVEL.....	5
2.2 - FUNCIONAMENTO DO MPC.....	6
2.3 - ESTRUTURA DO CONTROLADOR.....	7
2.3.1 - Camada inferior do MPC.....	8
2.3.2 - Camada superior do MPC.....	9
2.4 - FILTRO DE KALMAN.....	10
2.4.1 - Introdução.....	10
2.4.2 - Modelo do sistema e algoritmo do FK.....	13
2.4.3 - Considerações práticas.....	15
2.5 - COLUNA DEPROPANIZADORA.....	16
2.5.1 - Descrição do processo.....	17
2.5.2 - Especificação do produto e estratégias de controle.....	19
2.5.3 - Modelo do processo.....	20
CAPÍTULO 3 - ESTUDO DE CASO.....	23
3.1 - MPC APLICADO A COLUNA DEPROPANIZADORA.....	23
3.1.1 - Resultados e discussão.....	25
3.2 - FILTRO DE KALMAN APLICADO A COLUNA DEPROPANIZADORA.....	27
3.2.1 - Resultados e discussão.....	31
3.3 - APRIMORAMENTO DO DESEMPENHO DO MPC APLICADO A COLUNA DEPROPANIZADORA.....	34

CAPÍTULO 4 - CONCLUSÕES E SUGESTÕES.....	48
4.1 - CONCLUSÕES E SUGESTÕES.....	48
REFERÊNCIAS BIBLIOGRÁFICAS.....	49

LISTA DE FIGURAS

Figura 2.1	Esquema de implementação do algoritmo MPC.....	7
Figura 2.2	Estrutura em 2 camadas do MPC.....	8
Figura 2.3	Esquema do Estimador de Estados para Sistemas Discretos.....	11
Figura 2.4	Algoritmo do Filtro de Kalman.....	15
Figura 2.5	Esquema da UFCC da Refinaria RPBC.....	17
Figura 2.6	Fluxograma de processo da coluna depropanizadora.....	18
Figura 2.7	Tela do Supervisório da RPBC.....	19
Figura 2.8	Parâmetros do modelo identificado da coluna depropanizadora..	22
Figura 2.9	Modelo do processo (Coluna Depropanizadora).....	22
Figura 3.1	Diagrama Esquemático do MPC na Coluna Depropanizadora....	23
Figura 3.2	Controlador Preditivo aplicado a coluna depropanizadora.....	24
Figura 3.3	Resposta do MPC a alteração do setpoint da Concentração C3+ (Variável Controlada – Concentração de C3+ no Butano).....	25
Figura 3.4	Resposta do MPC a alteração do setpoint da Concentração C3+(Variável Controlada – Temperatura de Topo).....	26
Figura 3.5	Resposta do MPC a alteração do setpoint da Temperatura de Topo (Variável Controlada – Temperatura de Topo).....	22
Figura 3.6	Resposta do MPC a alteração do setpoint da Temperatura de Topo (Variável Controlada – Concentração de C3+ no Butano).	27
Figura 3.7	Estimador FK da Concentração C3+ no Butano x Variável do Processo sem ruído.....	31
Figura 3.8	Estimador FK da Temperatura de Topo x Variável do Processo sem ruído.....	32
Figura 3.9	Comparação entre variável com ruído, variável sem ruído e estimador FK (Concentração de C3+ no Butano).....	33
Figura 3.10	Comparação entre variável com ruído, variável sem ruído e estimador FK (Temperatura de Topo).....	33
Figura 3.11	Estados estimados pelo FK.....	34
Figura 3.12	Estimador FK e controle feedback aplicado ao MPC.....	34
Figura 3.13	Setpoint Fixo (0.88%) / Retroalimentação pelo FK a partir do t=500s (Concentração de C3+ no Butano - y1).....	36

Figura 3.14	Setpoint Fixo (49.24°C) / Retroalimentação pelo FK a partir do t=500s(Temperatura de Topo - y2).....	36
Figura 3.15	Saída do Controlador MPC - u1 (Vazão de Fluido de Aquecimento).....	37
Figura 3.16	Saída do Controlador MPC – u2 (Vazão de Refluxo de Topo)...	37
Figura 3.17	Alteração de setpoint da Concentração C3+ no instante t=1100s (Concentração de C3+ no Butano - y1).....	38
Figura 3.18	Alteração de setpoint da Concentração C3+ no instante t=1100s(Temperatura de Topo – y2).....	39
Figura 3.19	Saída do Controlador MPC – u1 (Vazão de Fluido de Aquecimento) /Alteração de setpoint da Concentração C3+ no instante t =1100s.....	40
Figura 3.20	Saída do Controlador MPC – u2 (Vazão de Refluxo de Topo)/ Alteração de setpoint da Concentração C3+ no instante t=1100s.....	40
Figura 3.21	Alteração de setpoint da Temperatura de Topo no instante t=1100s (Concentração de C3+ no Butano - y1).....	40
Figura 3.22	Alteração de setpoint da Temperatura de Topo no instante t=1100s (Temperatura de Topo – y2).....	41
Figura 3.23	Saída do Controlador MPC - u1 (Vazão de Fluido de Aquecimento)/Alteração de setpoint da Temperatura de Topo no instante t =1100s.....	41
Figura 3.24	Saída do Controlador MPC – u2 (Vazão de Refluxo de Topo)/ Alteração de setpoint da Temperatura de Topo no instante t=1100s.....	42
Figura 3.25	Avaliação do desempenho do MPC (Concentração de C3+ no Butano - y1 e setpoint fixo = 0.88).....	43
Figura 3.26	Avaliação do desempenho do MPC (Temperatura de Topo – y2 e setpoint fixo = 49.34).....	44
Figura 3.27	Avaliação do desempenho do MPC Targets e Saída do Controlador - (Vazão do Fluido de Aquecimento – u1).....	45
Figura 3.28	Avaliação do desempenho do MPC Targets e Saída do Controlador - (Vazão de Reciclo de Topo – u2).....	46

LISTA DE TABELAS

Tabela 2.1	Variáveis manipuladas e controladas do processo.....	21
Tabela 3.1	Funções de Transferência Linearizada da coluna C3/C4.....	23
Tabela 3.2	Parâmetros de Sintonia do MPC.....	24
Tabela 3.3	EQM (Concentração de C3+ no Butano - y_1 e Setpoint fixo=0.88).....	43
Tabela 3.4	EQM (Temperatura de Topo – y_2 e Setpoint fixo = 49.34).....	44
Tabela 3.5	EQM Targets e Saída do Controlador (Vazão do Fluido de Aquecimento).....	45
Tabela 3.6	EQM Targets e Saída do Controlador (Vazão do Fluido de Aquecimento).....	46

NOMENCLATURA

FK	FILTRO DE KALMAN
ISE	INTEGRAL DO ERRO QUADRÁTICO
ISDU	INTEGRAL DA DIFERENÇA DO ERRO QUADRÁTICO
LP	PROGRAMAÇÃO LINEAR
MPC	CONTROLADOR PREDITIVO MULTIVARIÁVEL
PID	PROPORCIONAL INTEGRAL DERIVATIVO
QP	PROGRAMAÇÃO QUADRÁTICA
SP	SETPOINT

CAPÍTULO 1

INTRODUÇÃO

1.1 - MOTIVAÇÃO

Com o aumento da competitividade dos sistemas produtivos, a necessidade de implementação de técnicas eficazes para minimização de custos e consequente maximização de lucro, se tornam imperativas. O desempenho dos sistemas de controle, a exemplo do Controle Preditivo Multivariável, em um processo industrial, tem extrema relevância nos quesitos: custo da produção e garantia da qualidade do produto entregue ao cliente.

Em geral, estes sistemas de controles industriais estão sujeitos a ruídos e imprecisões em suas variáveis de processo, ocasionando uma menor eficiência destes sistemas. Assim, pesquisas em técnicas para obter um maior desempenho nos sistemas de controles vêm sendo desenvolvidas nos últimos anos (DA SILVA, 2017).

Dentre as diversas técnicas desenvolvidas, a utilização de Filtro de Kalman para melhoria na qualidade das medições das variáveis de processo, antes da realimentação no sistema de controle, se destaca. Este efetua ajustes das variáveis medidas, com o objetivo de reduzir significativamente a propagação do ruído, aumentando a fidedignidade dessas variáveis, considerando as incertezas das variáveis do processo e do modelo.

O Filtro de Kalman (FK) é uma técnica de estimação de parâmetro utilizada em sistema lineares e estocásticos, e desde que foi teorizado por Rudolf Emil Kalman (KALMAN, 1960), foi consolidado em sua área de aplicação, se tornando a base para os estudos que lidam com a problemática da estimação de variáveis de estados e parâmetros. Tem como base algoritmos que combinam os sinais de saída do processo, medidos pelos sensores, com o conhecimento do modelo do sistema, para gerar os sinais observados.

No presente trabalho, são abordadas técnicas para implementação do Filtro de Kalman nas variáveis de processo de uma coluna depropanizadora, com objetivo de aprimorar o desempenho do Controlador Preditivo Multivariável (MPC).

1.2 - JUSTIFICATIVA DA PROPOSTA DE ESTUDO

O bom desempenho dos sistemas de controles em unidades industriais tem como objetivo principal a garantia de estabilidade do processo no ponto de operação desejado, de forma a garantir a qualidade final do produto, minimizando os custos de produção. Entretanto, caso a implementação destes sistemas de controle não seja realizada da forma correta, alguns resultados negativos são constatados, a exemplo:

- Aumento de custo de produção com matéria prima;
- Aumento dos custos de produção com energia (elétrica, combustível, vapor);
- Aumento das manutenções corretivas em equipamentos críticos;
- Fadiga Operacional em função da instabilidade de processo;
- Parada da produção industrial, a depender do nível de oscilação das variáveis.

Para alcançar a estabilidade do processo industrial é necessário, dentre várias condições, a correta definição da estratégia de controle e, principalmente, a garantia da qualidade na informação das variáveis do processo.

Diante desse contexto, a implementação de Filtro de Kalman em variáveis controladas nos processo industriais, apresenta-se com uma possibilidade de melhoria de performance do sistema de controle, tendo em vista que estas informações “filtradas” permitem uma melhor estabilidade do processo. Além disso, estas variáveis poderão ser utilizadas em inúmeras aplicações, inclusive na tomada de decisão operacional.

Assim sendo, o presente estudo tem relevância técnica e científica porque visa analisar a aplicação de técnica para aprimoramento de sistema de controle em um processo real, coluna depropanizadora, através da simulação MATLAB/SIMULINK.

1.3 - OBJETIVOS

1.3.1 - Objetivo geral

O objetivo geral desta pesquisa é analisar o desempenho do controlador preditivo multivariável, utilizado para controlar o processo da coluna depropanizadora, antes e após a implementação do Filtro de Kalman nas variáveis controladas do processo.

1.3.2 - Objetivos específicos

- Realizar o estudo teórico e a implementação numérica do Controlador Preditivo Multivariável em uma coluna depropanizadora;
- Realizar o estudo teórico da técnica e a implementação numérica do Filtro de Kalman (FK).

1.4 - CONTRIBUIÇÕES DA DISSERTAÇÃO

O presente trabalho torna-se relevante à medida que procura trazer contribuições teóricas e práticas para implementação de técnicas para melhoria de desempenho de sistemas de controle industriais, utilizando modelos de processos reais. Neste trabalho utilizaremos o modelo matemático do processo de uma coluna de depropanizadora da PETROBRAS (Refinaria Presidente Bernardes Cubatão/ RPBC), identificado no trabalho de Porfírio, 2001.

Outra contribuição é o emprego de uma ferramenta já validada e consolidada no meio acadêmico, Matlab, na solução de um problema muito comum na indústria.

1.5 - DELIMITAÇÃO

Apesar dos processos industriais reais normalmente serem não linearidade, inclusive a coluna depropanizadora estudada neste trabalho, para efeito deste, estudaremos o modelo do processo linearizado em um ponto de operação. Além disso, embora sejam as mais importantes, o modelo do processo utilizado neste trabalho leva em consideração apenas duas variáveis controladas e duas variáveis manipuladas, diferentemente do processo real.

1.6 - ORGANIZAÇÃO DO TRABALHO

O capítulo 1 enfatiza as motivações, a justificativa da proposta do estudo que levaram ao tema de aprimoramento do desempenho do controlador preditivo com a implementação do Filtro de Kalman nas variáveis controladas, e também discorre os objetivos pretendidos no presente trabalho.

O capítulo 2 apresenta uma revisão da literatura e o estado da arte acerca de Controle Preditivo Multivariável, Filtro de Kalman e sobre a Coluna Depropanizadora.

O capítulo 3 demonstra os resultados do estudo de caso. Primeiramente é implementado o sistema de controle, MPC, junto a planta (coluna depropanizadora) e apresentado os resultados. Logo em seguida, é implementado o filtro de kalman nas variáveis controladas (concentração de c_3+ no butano e temperatura de topo). Por último, é avaliada a performance do controlador preditivo após a implementação do filtro de kalman nas variáveis controladas realimentando o sistema de controle.

O capítulo 4 apresenta a conclusão do trabalho através do resumo dos resultados encontrados, bem como é apresentada sugestões para continuação do trabalho.

CAPÍTULO 2

REVISÃO DA LITERATURA

1.1 - CONTROLE PREDITIVO MULTIVARIÁVEL

Controle Preditivo Multivariável (MPC) refere-se a uma classe de algoritmos de controle que controla a resposta futura de uma planta através do uso de um modelo explícito do processo.

As ideias do MPC tiveram início a partir de 1960 (GARCÍA *et al.*, 1989), porém, o real interesse nesse campo começou a crescer a partir de 1980, depois dos trabalhos sobre o MPHC (Model Predictive Heuristic Control) e o DMC (Dynamic Matrix Control), e particularmente, depois do QDMC (Quadratic Dynamic Matrix Control), que ficaram muito populares na indústria petroquímica e nas estações de força. Desde essa época, têm surgido novas variantes MPC, tais como: MAC, IMC, GPC, MOOCA, HIECON, PFC, OPC, PCT e RMPCT.

Atualmente, a técnica de controle avançada mais utilizada na indústria de processos é o MPC, sendo geralmente implementada no nível médio de uma estrutura de controle global. O sucesso desta técnica pode ser atribuído a três fatores importantes (SOTOMAYOR, 2002):

- Primeiro, a incorporação de um modelo explícito do processo na lei de controle, o que permite ao controlador, em princípio, lidar diretamente com todas as características significantes da dinâmica do processo.
- Segundo, o MPC considera a resposta da planta sobre um horizonte futuro no tempo, assim os efeitos da pré-alimentação e realimentação de perturbações podem ser antecipados e removidos, permitindo ao controlador levar o processo mais perto da trajetória futura desejada.
- Finalmente, o MPC considera restrições nos estados, nas entradas e nas saídas, diretamente no cálculo da lei de controle. Isto significa que violações das restrições são menos prováveis de acontecerem, resultando em um controle justo no estado estacionário ótimo, com restrições, para o processo. A inclusão de restrições é a característica principal que distingue o MPC dos outros algoritmos de controle

1.1 - FUNCIONAMENTO DO MPC

Os Controladores Preditivos Multivariáveis (MPC) são implementados, normalmente, em uma camada hierarquicamente superior a camada do controle regulatório. Nesta configuração, o controlador preditivo fornece setpoints ótimos para a camada de controle regulatório, conforme Figura 2.2.

Quanto ao seu funcionamento, utilizando o modelo do processo real, as respostas deste processo às mudanças nas variáveis manipuladas são previstas. No instante de tempo atual, usualmente definido como k , o comportamento do processo ao longo do tempo np é considerado. Este intervalo de tempo $[k, np]$ é conhecido como horizonte de predição. As ações das variáveis manipuladas são selecionadas de tal forma que a resposta prevista apresenta determinadas características que sejam desejáveis. As ações de controle, das variáveis manipuladas, podem variar durante um horizonte de controle $m < np$ (DA SILVA, 2017).

Tanto o horizonte de controle como o de predição faz parte da sintonia do MPC (GOMES, 2009). Desta forma, minimiza-se um critério de desempenho sujeito à dinâmica do processo e às possíveis restrições nas variáveis de saída e entrada. Porém, apenas a primeira ação de controle calculada é de fato implantada no processo. No próximo instante de amostragem, isto é, em $k+1$, o mesmo problema de otimização é resolvido com a nova condição inicial, obtida mediante informações tirada das medidas do processo em $k+1$ e com o horizonte movido adiante por um intervalo de amostras (QUIN e BADGWALL, 2003). A Figura 2.1 abaixo ilustra a implementação básica do algoritmo de controle MPC.

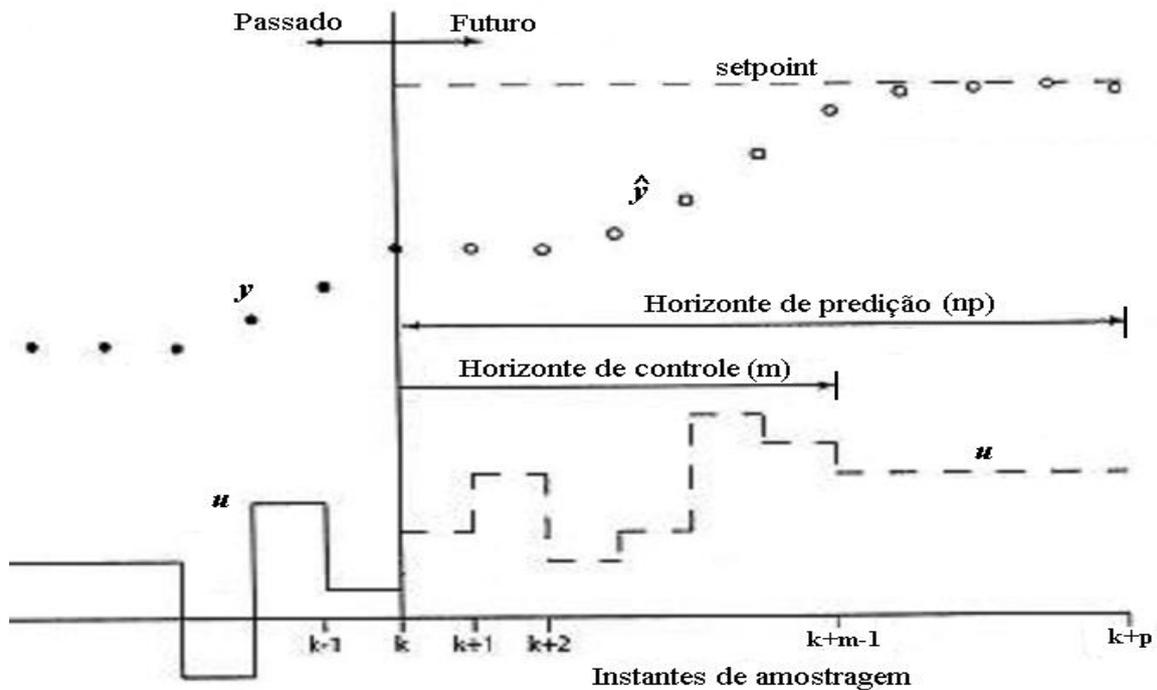


Figura 2.1 – Esquema de implementação do algoritmo MPC.
 Fonte: SOTOMAYOR (2009).

1.1 - ESTRUTURA DO CONTROLADOR

Muitos dos MPC comerciais operam numa estrutura em duas camadas: Superior e Inferior. Na camada superior, o algoritmo de otimização econômica computa um ótimo estado estacionário. O resultado deste problema é enviado para camada inferior, MPC, através de valores desejados para as variáveis manipuladas (“targets”). Na camada inferior é resolvido outro problema de otimização, entretanto levando-se em conta a dinâmica do processo. Geralmente os algoritmos de otimização são resolvidos através de programação linear (LP) ou programação quadrática (QP), no mesmo intervalo de amostragem (SOTOMAYOR *et al.*, 2009).

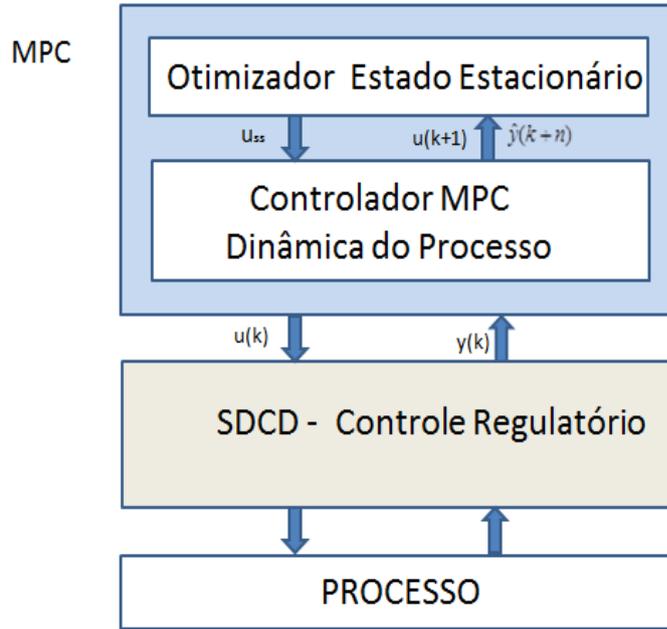


Figura 2.1 – Estrutura em 2 camadas do MPC.

2.3.1 - Camada inferior do MPC

Na camada inferior, ou seja, no MPC, minimiza-se uma função objetivo, J , desejado sujeito à dinâmica do processo e às possíveis restrições nas variáveis manipuladas e controladas.

$$\min_{\Delta u_k} J \quad (2.1)$$

Sujeito a

$$J = \sum_{j=1}^{np} [y(k+j) - y^{sp}]^T Q [y(k+j) - y^{sp}] + \sum_{j=0}^{m-1} \Delta u(k+j)^T R \Delta u(k+j) \quad (2.2)$$

$$-\Delta u^{\max} \leq u(k+j) \leq \Delta u^{\max}, \quad j=0,1,\dots,m-1 \quad (2.3)$$

$$\Delta u(k+j) = 0, \quad j \geq m \quad (2.4)$$

$$u^{\min} \leq u(k+j) \leq u^{\max}, \quad j=0,1,\dots,m-1 \quad (2.5)$$

Em que:

$\Delta u_k = \left[\Delta u(k)^T \Delta u(k+1)^T \dots \Delta u(k+m-1)^T \right]^T$ variação das entradas calculada no instante k

u vetor das entradas manipuladas do sistema

y vetor das saídas controladas do sistema

y^{sp} vetor do sinal de referência (setpoints) das saídas do sistema

np horizonte de predição

m horizonte de controle

Q matriz de ponderação (pesos) das saídas

R matriz de ponderação das entradas (fatores de supressão)

J_k função objetivo ou função de custo

2.3.2 - Camada superior do MPC

A otimização em estado estacionário, soluciona, no mesmo instante de amostragem do controlador MPC, um problema de programação quadrática ou linear, usando o modelo do processo em estado estacionário e informações provenientes do controlador.

O resultado da otimização estacionária (valores otimizados para setpoint das variáveis controladas e targets para as variáveis manipuladas) é enviado para a implementação do MPC (YING e JOSEPH, 1999; QIN e BADGWELL, 2003; ENGELL, 2007).

A formulação da otimização estacionária implica a minimização dos desvios entre os valores ótimos a serem implementados no MPC. Para isto o seguinte problema é solucionado:

$$\min_{u_{ss}} (u_{ss} - u(k-1))^T Q_1 (u_{ss} - u(k-1)) + Q_2 \cdot (u_{ss} - u(k-1)) \quad (2.6)$$

sujeito a:

$$\begin{aligned}y_{ss} &= Gu_{ss} + d_s \\d_s &= \hat{y}(k+n) - Gu(k-1) \\u_{\min} &\leq u_{ss} \leq u_{\max} \\y_{\min} &\leq y_{ss} \leq y_{\max}\end{aligned}\tag{2.7}$$

Em que: $u(k-1)$ é a última ação de controle implementada, k é o instante atual, u_{ss} é o vetor de “targets” em estados estacionário, y_{ss} é o vetor de saídas previstas em estado estacionário, $\hat{y}(k+n)$ é a previsão das saídas controladas para o instante $k+n$ (n é o horizonte de estabilização do processo), d_s é o valor da perturbação em estado estacionário (modelo do bias) e G é a matriz de ganho em estado estacionário do processo (KASSMANN e BADGWELL, 2000). Já y_{max} e y_{min} são os limites máximos e mínimos das saídas controladas y , Q_1 e Q_2 são as matrizes de ponderação com dimensões apropriadas.

A otimização estacionária aumenta o grau de robustez do controlador, proporciona um desempenho livre de erros estacionários (“offsets”) e permite que as saídas sejam controladas por setpoint fixo ou por faixa (SOTOMAYOR *et al*, 2009).

2.4 - FILTRO DE KALMAN

2.4.1 - Introdução

Em todos os processos industriais as variáveis de processo obtidas através de medição estão sujeitas a ruídos, sendo que estes afetam significativamente o desempenho do processo. Com o objetivo de reduzir os efeitos dos erros de medição, são usadas técnicas que podem estimar os estados e parâmetro deste processo a partir de modelos matemáticos com a finalidade de reduzir estes erros aleatórios (DA SILVA, 2017).

Essa técnica é conhecida como estimadores de estados ou filtro estocásticos.

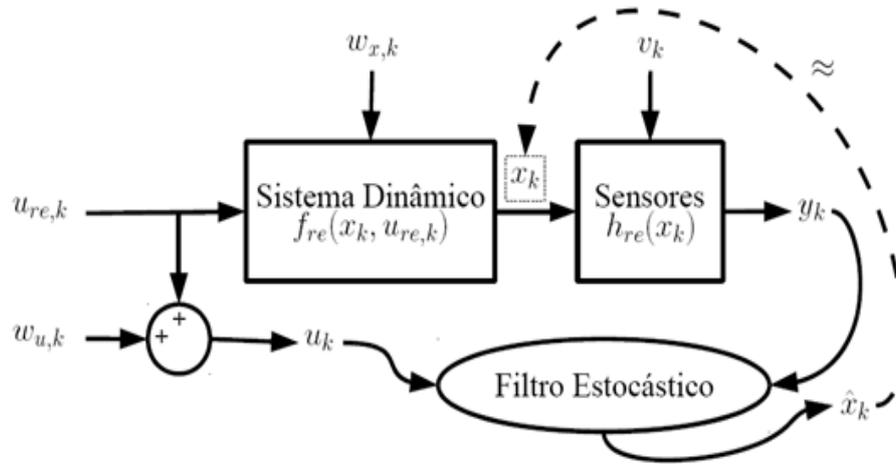


Figura 2.3 – Esquema de implementação do algoritmo MPC.
 Fonte: Adaptada de SIMON (2006).

Dentre estas técnicas de estimação, para sistemas lineares, destaca-se o Filtro de Kalman. Este dá estimativas ótimas na presença de incertezas na medição e no estado. Outra característica importante do Filtro de Kalman e suas variações, é que estes possuem estimação de natureza recursiva, fato que proporciona uma rápida estimação em tempo real, o que é extremamente importante para desenvolvimento on-line.

Em 1960, Kalman publicou artigo no qual era descrito procedimento para resolução de problemas lineares através de estimação de estados (KALMAN, 1960). Na versão inicial, apenas os problemas em tempo discreto foram abrangidos, entretanto ainda nessa década, Kalman e Bucy desenvolveram a implementação para problemas em tempo contínuo (KALMAN e BULCY, 1961).

O Filtro de Kalman é um estimador instantâneo de determinado estado perturbado por ruído, em sistema dinâmico linear. É estatisticamente eficiente com relação a qualquer função quadrática de erros de estimativa (GREWAL e ANDREWS, 2014), na qual suas equações formam um processo recursivo capaz de reduzir a soma dos quadrados das diferenças entre os valores medidos e os estimados.

A partir do modelo do processo e medições ruidosas deste, o FK estima, de forma precisa, os estados e parâmetros do processo, mitigando os efeitos dos erros randômicos inerentes aos processos de medição. Em geral, considera-se como um propagador de distribuição probabilística, já que fornece uma caracterização completa do estado atual de um sistema, incluindo referências passadas, sem necessitar efetivamente dos valores anteriores (JUNIOR, 2016).

OLIVEIRA (2005) propôs utilizar técnica de filtragem de kalman e vetor de estados com dimensão variável para acompanhamento de alvos radar. A análise com dados simulados e com dados reais demonstram a viabilidade e a vantagem de utilização destas técnicas.

Em ABREU (2008) foi analisada a aplicação de Filtro de Kalman para a fusão de informação de sensores de um robô para a sua auto localização. Neste sentido, foi desenvolvido algoritmo, em Matlab, que simula o deslocamento de um móvel unidimensional, como um comboio, juntamente com o Filtro de kalman e observou-se que, mesmo com a presença de eventuais distúrbios, o FK foi capaz de fazer a estimativa convergir para o valor real.

A utilização de Filtro de kalman na estimação de estados de um problema de rastreamento de um veículo de dinâmica desconhecida a partir de outros veículos é analisada em FARIA (2010). Como resultado, foi observado que as estimativas encontradas convergiam com os valores reais e com o tempo de convergência bastante favorável.

VINHAL (2013) utilizou FK como ferramenta para pré-processamento de sinais espectrofotométricos no contexto da quimiometria. O sinal filtrado é usado na calibração multivariada para construir um modelo matemático com boa capacidade preditiva. Os resultados obtidos demonstraram que pode ser aplicado com vantagens em relação a outras técnicas tradicionais em quimiometria.

Em MACHADO (2014), o FK foi implementado em hardware tipo FPGA (Field Programmable Gate Arrays), de forma a garantir através dessa implementação, uma plataforma rápida o suficiente para rastrear radares de foguetes com alta precisão.

JUNIOR (2016) demonstrou aplicação de FK de forma a garantir a qualidade de energia em equipamentos elétricos, reduzindo a possibilidade de danos. O algoritmo de sincronia e a filtragem do sinal de tensão da rede foram implementados baseando-se na teoria de filtro de kalman para modelo linear.

Para aplicação em sistemas não lineares existem algumas variações do Filtro de kalman, dentre elas, o Filtro de Kalman Estendido (EKF) e o Filtro de Kalman Unscented (UKF).

2.4.2 - Modelo do sistema e algoritmo do FK

O Filtro de Kalman foi proposto por Kalman (1960) sendo um estimador linear para sistemas lineares da forma:

$$\begin{aligned}x_k &= A_{k-1}x_{k-1} + B_{k-1}u_{k-1} + w_{k-1} \\y_k &= C_k x_k + v_k\end{aligned}\quad (2.8)$$

sendo:

- k o tempo atual;
- x_k o estado no tempo k ;
- x_{k-1} o estado no tempo $k-1$;
- u_{k-1} a entrada do processo no tempo $k-1$ (variável manipulada);
- w_{k-1} o ruído do modelo do processo no tempo $k-1$;
- A, B e C matrizes de controle do sistema dinâmico;
- v_k ruído da medição;
- y_k variável do processo.

Para grande parte das aplicações de sistemas dinâmicos, incluindo a desejada nesse trabalho, os ruídos w_{k-1} , v_k são considerados ruídos Gaussianos brancos não correlacionados, oriundo de erro de modelagem e dos sensores de medição, respectivamente. Com isso, tais ruídos têm média zero e covariância Q_{k-1} e R_k :

$$\begin{aligned}w_{k-1} &\sim N(0, Q_{k-1}) \\v_k &\sim N(0, R_k)\end{aligned}\quad (2.9)$$

Considerando que o modelo do sistema já foi definido nas equações (8), o algoritmo do FK pode ser apresentado. Em resumo, o algoritmo consiste na predição, onde o valor do estado e da matriz de covariância do erro são estimados a priori e, em seguida, são feitas as correções dessas predições, através do ganho de kalman.

Na predição, são estimados os estados, \bar{x}_k , e a matriz de covariância do erro, \bar{P}_k , no tempo k , baseados nos valores do passo anterior, no tempo $k-1$.

A estimativa inicial, conhecida como a priori, do estado, é baseada na estimativa do próprio estado no passo anterior, $k-1$, ponderado pela matriz de controle, A_{k-1} ,

somada ao valor da entrada do processo no tempo k-1, u_{k-1} , ponderada pela matriz de controle, B_{k-1} , conforme Eq. (2.10).

$$\bar{x}_k = A_{k-1}\hat{x}_{k-1} + B_{k-1}\bar{u}_{k-1} \quad (2.10)$$

Quanto a estimativa da matriz de covariância do erro a priori, \bar{P}_k , esta é baseada no seu próprio valor no passo anterior, \hat{P}_{k-1} , ponderada pelas matrizes de controle e suas transpostas, $A_{k-1}, A_{k-1}^T, B_{k-1}, B_{k-1}^T$, e somada com o ruído de processo no tempo k-1, Q_{k-1} , conforme abaixo.

$$\bar{P}_k = A_{k-1}\hat{P}_{k-1}A_{k-1}^T + B_{k-1}P_{u,k-1}B_{k-1}^T + Q_{k-1} \quad (2.11)$$

Em seguida, após a etapa da predição, são realizados os cálculos de correção, na qual são novamente estimados os estados de interesses, \hat{x}_k e a matriz de covariância do erro, \hat{P}_k , porém com a atualização dos mesmos a partir do ganho de Kalman.

O ganho de Kalman, K_k , é baseado no valor estimado da matriz de covariância do erro, \bar{P}_k , encontrado na predição, e outras matrizes, a exemplo de R_k e C_k , conforme equação abaixo.

$$K_k = \bar{P}_k C_k^T (R_k + C_k \bar{P}_k C_k^T)^{-1} \quad (2.12)$$

Este parâmetro tem por finalidade minimizar o valor estimado na matriz de covariância do erro, \bar{P}_k , com a intenção de estimar o valor do estado.

Após, é calculada uma nova estimativa do estado, \hat{x}_k , conhecida como a posteriori, atualizando a estimativa encontrada anteriormente, \bar{x}_k , com base no ganho de Kalman, K_k , na já citada matriz C_k , e na medição realizada no passo atual, y_k , no tempo k.

$$\hat{x}_k = \bar{x}_k + K_k(y_k - C_k \bar{x}_k) \quad (2.13)$$

Por ultimo, uma nova estimativa a posteriori da matriz de covariância do erro, \hat{P}_k , é também calculada, levando-se em conta a estimativa obtida na predição, \bar{P}_k , a matriz C_k e o ganho de Kalman, cujo objetivo é minimizar esse erro,

$$\hat{P}_k = (I - K_k C_k) \bar{P}_k (I - K_k C_k)^T + K_k R_k K_k^T \quad (2.14)$$

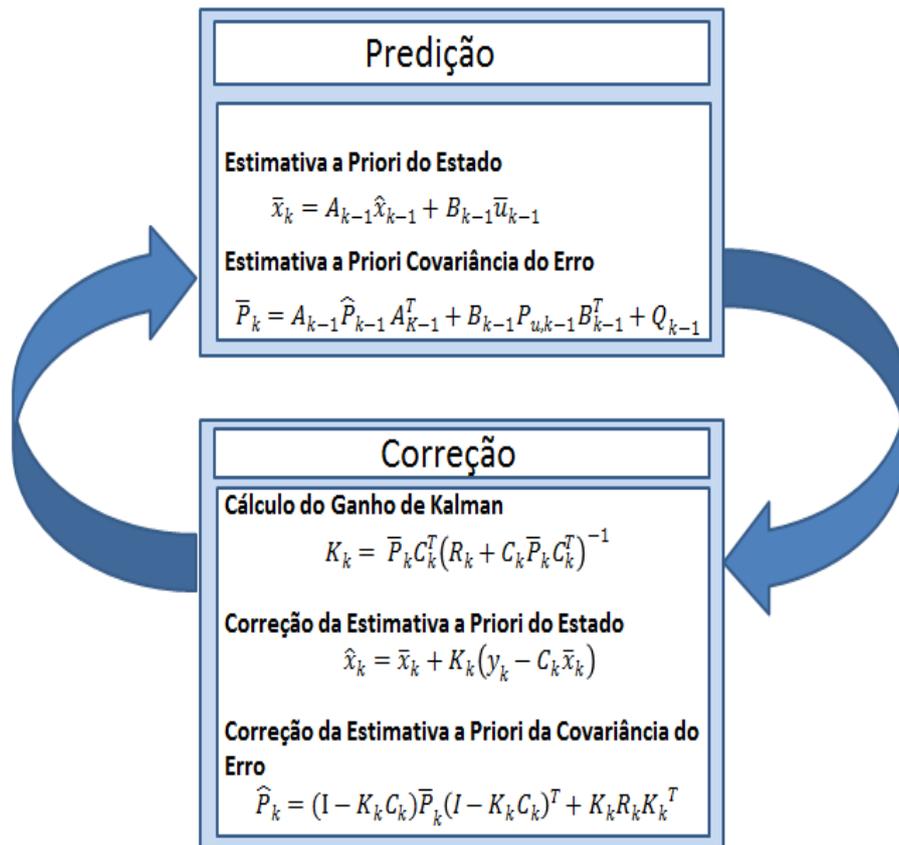


Figura 2.4 – Algoritmo do Filtro de kalman.

2.4.3 - Considerações práticas da implementação do filtro de Kalman

O Filtro de Kalman é uma ferramenta de estimação muito atrativa, pois o mesmo apresenta um desempenho ideal caso suas suposições teóricas sejam respeitadas. Porém, em um ambiente prático, o projetista perceberá que nunca será possível encontrar uma situação onde nenhuma das suposições seja violada, impedindo uma aplicação com sucesso total, ou seja, desempenho ideal. De acordo com AGUIRRE (2007) e SIMON (2006), as razões mais comuns para problemas de estimação do filtro são erros de modelagem e a precisão aritmética finita.

A teoria do Filtro de Kalman assume precisão aritmética infinita, o que garantiria certa estabilidade e convergibilidade ao filtro. Mesmo atualmente, com os processadores dos computadores cada vez mais avançados, a precisão aritmética ainda possui limites. Em sistemas embarcados, que apresentam precisão ainda menor, é onde o problema fica mais acentuado, podendo causar alta divergência e instabilidade. (AGUIRRE, 2007).

No intuito de melhorar o desempenho do FK, o projetista pode utilizar algumas estratégias (SIMON, 2006):

- Precisão Aritmética

i. Tomar cuidados com as estimativas iniciais de estado e matriz de covariância de erro de estimação, inicializando os valores de acordo com o conhecimento do sistema. Apesar de nem sempre resolver os problemas de divergência, uma inicialização mal feita pode fazer com que o FK aprenda o modelo errado muito rapidamente ou ficar insensível à entrada de novas informações;

ii. Se possível, melhorar a precisão aritmética do filtro fazendo alterações nas variáveis do algoritmo, no intuito de aproximar o comportamento digital do FK à teoria analógica.

- Modelagem do Sistema:

i. Fazer com que o filtro esqueça medições mais antigas, e apenas usar uma faixa mais nova de medidas para gerar as estimativas do estado. O FK deixaria de ser ótimo teoricamente, mas poderia garantir a convergência do mesmo na prática. O filtro passaria a dar menos importância ao modelo assumido pelo projetista e daria mais ênfase às medições encontradas;

ii. Implementação heurística de ruído aditivo na dinâmica da variável de estado, que pode ser feito de maneira simples pelo projetista. Este método é matematicamente equivalente ao anterior, pois a adição desse ruído informa ao filtro para confiar menos no modelo adotado para o processo e para enfatizar mais as medições feitas da saída.

2.5 - COLUNA DEPROPANIZADORA

As unidades de refino de petróleo possuem diversos estágios de processamento, os quais possuem com funções específicas. Neste trabalho, analisaremos um dos processos contidos na Unidade de Craqueamento Catalítico Fluido, UFCC, e presentes em algumas Refinarias de Petróleo, a coluna depropanizadora.

Nas refinarias da PETROBRAS, estas colunas normalmente estão presentes no estágio final das nas unidades de Craqueamento Catalítico Fluido (UFCC's), tendo a função de separar a corrente de propano da corrente de butano, garantindo rigorosamente a especificação destas correntes.

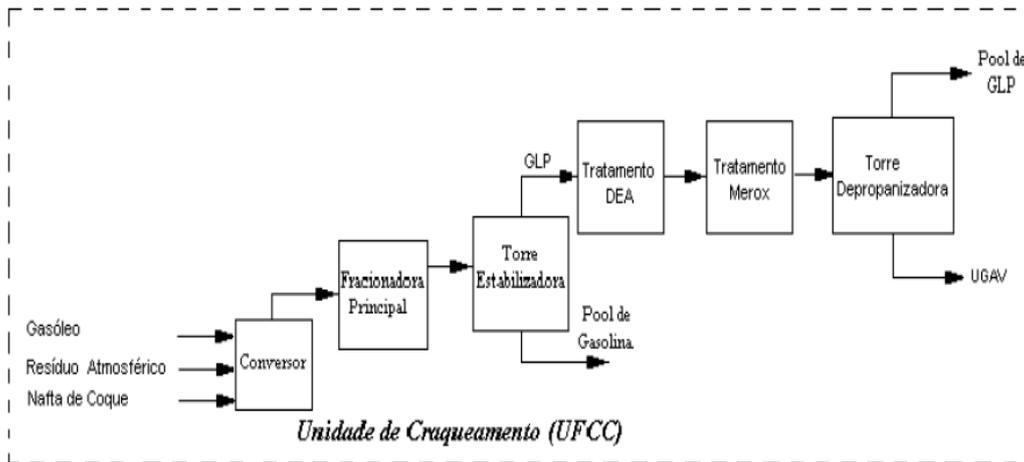


Figura 2.5 – Esquema da UFCC da Refinaria RPBC.
Fonte: PORFIRIO (2001).

2.5.1 - Descrição do processo

A coluna depropanizadora, processo estudado neste trabalho, já foi anteriormente identificada e modelada, conforme trabalho de PORFIRIO (2001). Esta pertence à unidade de craqueamento catalítico da Refinaria da Petrobras, RPBC (Refinaria Presidente Bernardes) e está representada na Figura 2.6. Para maiores informações sobre o processo esse trabalho pode ser consultado.

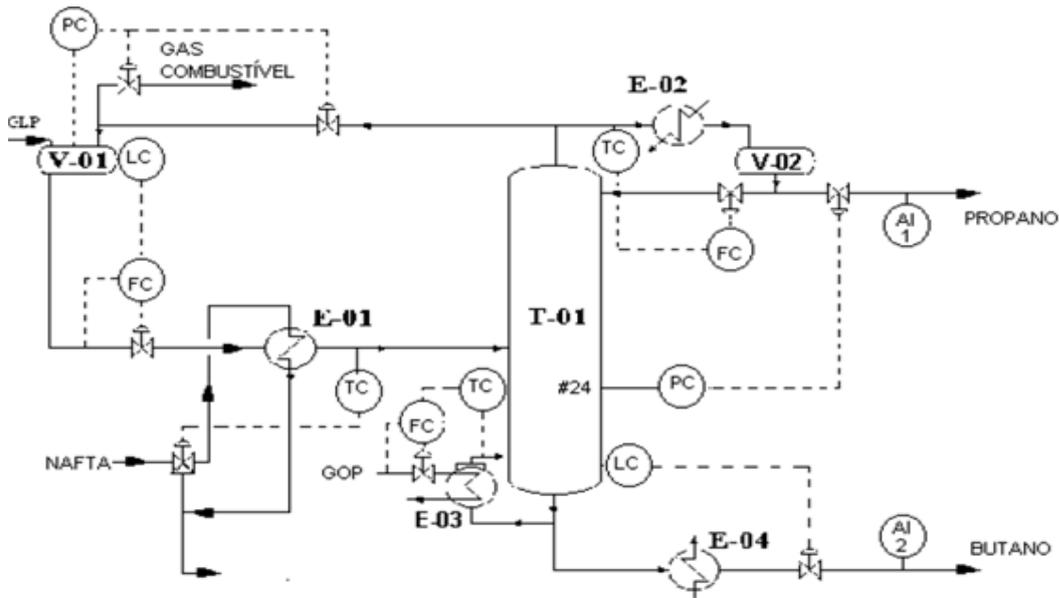


Figura 2.6 – Fluxograma de processo da coluna depropanizadora.
Fonte: PORFIRIO (2001).

Antes de chegar ao processo da coluna de depropanização, fluxograma acima, o GLP passa pela seção de tratamento, a qual possui duas etapas: tratamento com DEA para remoção de contaminantes (CO₂, CO e H₂S) e tratamento com Merox para remoção de compostos de enxofre (mercaptans). Esse processo tem como objetivo a eliminação da corrosividade do GLP.

Após passar pela seção de tratamento, o GLP é enviado para o vaso V-01, o qual possui um controle de nível em cascata com a vazão de saída do GLP. Após o vaso V-01, o GLP é bombeado para a coluna T-01, sendo antes preaquecido no trocador de calor E-1, através da troca térmica com a nafta proveniente do fundo da torre de debutanizadora. Para manter o controle da temperatura na entrada da coluna T-01, existe um controle regulatório de temperatura que mantém esta temperatura do GLP fixa, manipulando a vazão de nafta para o trocador, através da manipulação de válvulas.

Após o preaquecimento do GLP, esta carga é destilada na coluna T-01, sendo os vapores totalmente condensados e subresfriado no trocador E-2 e enviados para o vaso de topo, V-02. Neste vaso, a corrente líquida é dividida em duas partes, sendo uma para refluxo de topo e outra retirada como destilado para o pool de GLP.

Na parte inferior da coluna, parte do refluxo interno que atinge o fundo da coluna é vaporizado no refeedor E-03 e a outra parte é retirada, resfriada no E-04, e enviada para a unidade de gasolina de aviação.

2.5.2 - Especificação do produto e estratégias de controle

Segundo PORFIRIO (2001), para garantirmos a especificação das duas correntes (propano e butano) que saem da coluna, as seguintes variáveis devem ser observadas: Vazão de carga da coluna; Temperatura de carga da coluna; Composição da carga; Pressão da coluna; vazão de refluxo; Vazão de fluido de aquecimento para refeedor; Temperatura de Topo da Coluna.

Dentre estas, as duas principais variáveis são: Vazão de refluxo e Vazão de fluido de aquecimento para o refeedor. A vazão de refluxo do topo está diretamente relacionada com a especificação do teor de C4+ no propano, já a vazão de fluido de aquecimento para o refeedor, está diretamente relacionada à especificação do teor de C3- no butano.

Neste sentido, considerando que o controle da coluna depropanizadora é por definição um problema multivariável, o controle preditivo tende a ser a melhor escolha para este propósito. Na RPBC existe implementado o controle preditivo multivariável na coluna depropanizadora. A seguir na Figura 2.7 é apresentada a tela de controle onde os Técnicos de Operação acompanham o processo.

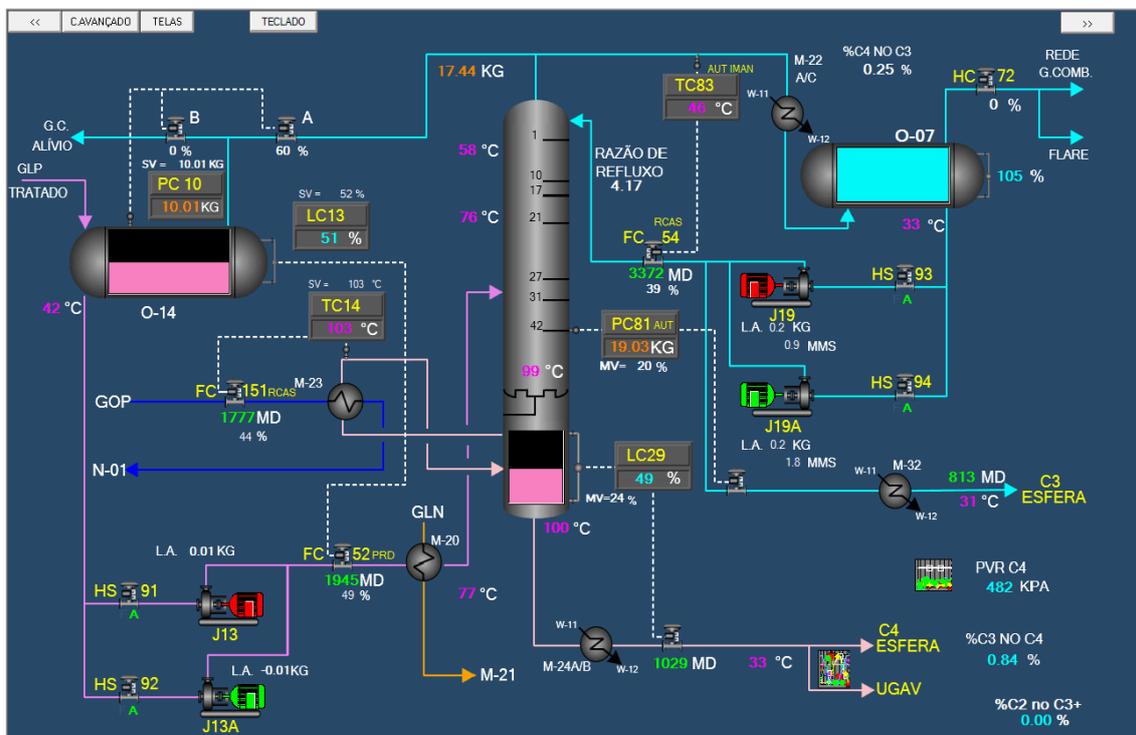


Figura 2.7 – Tela do Supervisório da RPBC.

2.5.3 - Modelo do processo

O comportamento dinâmico da maioria dos processos pode ser representado por equações diferenciais de primeira ou segunda ordem. Mesmo os processos químicos que possuem ordens elevadas podem ser razoavelmente aproximadamente para modelos de primeira ou segunda ordem. Neste trabalho, utilizaremos um dos modelos matemático no domínio da frequência obtido no trabalho de PÓRFIRO (2001).

Abaixo, segue a equação no domínio da frequência para modelos de segunda ordem, utilizado como modelo do processo estudado neste trabalho.

$$G(s) = \frac{b_0 + b_1 s}{1 + a_1 s + a_2 s^2} e^{-s\theta} \quad (2.15)$$

Considerando o modelo sem tempo morto, temos:

$$G(s) = \frac{b_0 + b_1 s}{1 + a_1 s + a_2 s^2} \quad (2.16)$$

Aplicando o degrau em sistema sem tempo morto, temos:

$$y_d(s) = \frac{1}{s} G(s) \quad (2.17)$$

substituindo a Eq. (2.16) em Eq. (2.17), temos;

$$y_d(s) = \frac{b_0 + b_1 s}{1 + a_1 s + a_2 s^2} \times \frac{1}{s} \quad (2.18)$$

fatorando $y_d(s)$, temos;

$$y_d(s) = \frac{b_0 + b_1 s}{(\tau_1 s + 1)(\tau_2 s + 1)s} \quad (2.19)$$

ou

$$y_d(s) = \frac{1}{\tau_1 \tau_2} \frac{b_0 + b_1 s}{(s + \frac{1}{\tau_1})(s + \frac{1}{\tau_2})s} \quad (2.20)$$

Portanto as raízes do denominador são:

$$r_1 = -\frac{1}{\tau_1}; r_2 = -\frac{1}{\tau_2}; r_3 = 0 \quad (2.21)$$

Então a resposta ao degrau pode ser apresentada por:

$$y_d(s) = r_1 r_2 \frac{b_0 + b_1 s}{(s + r_1)(s + r_2)s} \quad (2.22)$$

Separando a resposta ao degrau em frações parciais, temos:

$$y_d(s) = \frac{c_0}{s} + \frac{c_1}{(s-r_1)} + \frac{c_2}{(s-r_2)} \quad (2.23)$$

sendo:

$$c_0 = b_0$$

$$c_1 = r_2 \frac{b_0 + b_1 r_1}{(r_1 - r_2)} \quad \text{ou} \quad c_1 = \frac{b_0 \frac{1}{r_1} + b_1}{\left(\frac{1}{r_2} - \frac{1}{r_1}\right)}$$

$$c_2 = r_1 \frac{b_0 + b_1 r_2}{(r_2 - r_1)} \quad \text{ou} \quad c_2 = \frac{b_0 \frac{1}{r_2} + b_1}{\left(\frac{1}{r_1} - \frac{1}{r_2}\right)} \quad (2.24)$$

Passando a resposta para o domínio do tempo e incluindo o tempo morto, θ , temos:

$$y_d(t) = c_0 + c_1 e^{r_1(t-\theta)} + c_2 e^{r_2(t-\theta)} \quad (2.25)$$

Para identificação do modelo do processo, foram aplicados degraus, de forma isolada, nas variáveis manipuladas e acompanhado o comportamento das variáveis controladas.

Tabela 2.1 - Variáveis manipuladas e controladas do processo.

Variáveis manipuladas	Variáveis Controladas
Vazão de refluxo de topo;	Temperatura de Topo
Vazão de fluido de aquecimento;	Concentração de C3- no butano
Vazão de Carga;	
Temperatura do fluido de Aquecimento;	

Os efeitos da aplicação do degrau no processo foram acompanhados através do SDCD da refinaria, analisando a resposta do processo através das duas variáveis controladas: Temperatura de Topo e concentração de C3- no butano. Através de um software de identificação, foram identificados os parâmetros da Eq. (2.16), conforme Figura 2.8.

MODELO	CV	MV/DV	b_0	b_1	a_1	a_2	θ
FD	C_3^-	V_{RF}	0.5656e-3	-0.2218e-3	3.4948	0.5902	1
		V_{GOP}	-0.001452	0.00007413	2.6987	0.4023	1
		V_{carga}	0.0001125	-0.0001138	0.4559	0.03227	1
		T_{GOP}	-0.01642	-0.01324	1.438	0.184	1
	C_4^+	V_{RF}	-	-	-	-	1
		V_{GOP}	-	-	-	-	1
		V_{carga}	-	-	-	-	1
		T_{GOP}	-	-	-	-	1
	T_{TOPO}	V_{RF}	-0.001235	-0.001135	1.6380	0.09852	1
		V_{GOP}	0.0020	-0.0003	2.4298	0.0651	1
		V_{carga}	-0.0003829	0.0001715	0.2295	0.02632	1
		T_{GOP}	0.006970	0.001998	0.1731	0.01045	1

Figura 2.8 – Parâmetros do modelo identificado da coluna depropanizadora.
Fonte: Adaptado de PORFIRIO (2001).

A concentração de C_4^+ no propano não foi considerada como variável controlada no modelo matemático identificado, uma vez que o medidor de campo não apresentava, na ocasião, confiabilidade na informação. Sendo assim a Temperatura de Topo foi definida como variável para monitoramento e controle da especificação do butano.

Para efeito deste trabalho, o modelo linear 2x2 abaixo, representa o processo “real” da coluna C3/C4, identificados através de testes na planta da Refinaria RPBC.

$$G_p = \begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{-0.2218 * 10^{-3}s + 0.5656 * 10^{-3}}{s^2 + 3.4948s + 0.5902} & \frac{0.00007413s + 0.001452}{s^2 + 2.6987s + 0.4023} \\ \frac{-0.001135s + 0.001235}{s^2 + 1.6380s + 0.09852} & \frac{-0.0003s + 0.0020}{s^2 + 2.4298s + 0.0651} \end{bmatrix}$$

Figura 2.9 – Modelo do processo (Coluna Depropanizadora).

CAPÍTULO 3

ESTUDO DE CASO

3.1 - MPC APLICADO A COLUNA DEPROPANIZADORA

Nesta seção, apresentaremos algumas características da implementação do controlador MPC e os resultados das simulações realizadas. Na Figura 3.1 ilustra-se o esquema do controlador MPC no processo da coluna depropanizadora, com suas respectivas variáveis controladas e manipuladas. Optou-se pela utilização do MPC, uma vez que o problema é multivariável e apresenta elevada interação entre as variáveis.

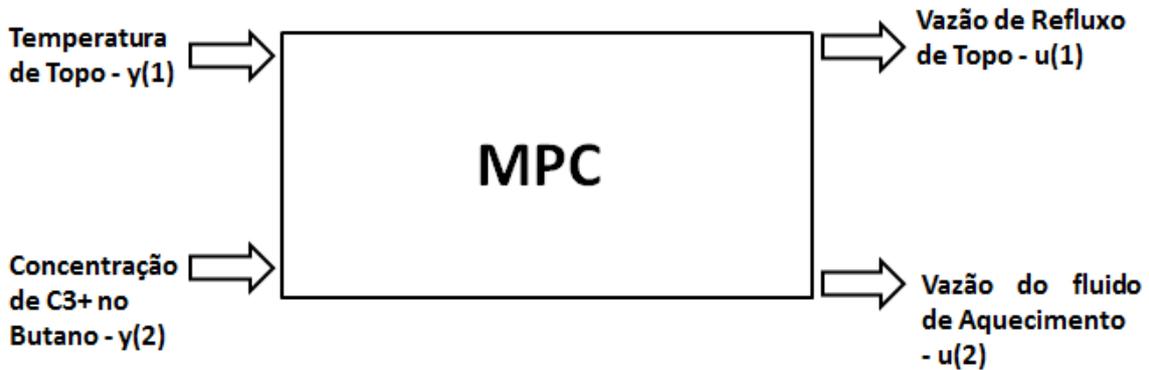


Figura 3.1 – Diagrama esquemático do MPC na coluna depropanizadora.

Na Tabela 3.1 são mostradas as funções de transferência do sistema linearizado no ponto de operação identificado.

Tabela 3.1 - Funções de Transferência Linearizada da coluna C3/C4.

Entrada/Saída	Concentração de C3+ y(1)	Temperatura de Topo y(2)
Vazão do Fluido de Aquecimento u(1)	$\frac{-0.2218 \cdot 10^{-3}s + 0.5656 \cdot 10^{-3}}{s^2 + 3.4948s + 0.5902}$	$\frac{0.00007413s + 0.001452}{s^2 + 2.6987s + 0.4023}$
Vazão de Refluxo u(2)	$\frac{-0.001135s + 0.001235}{s^2 + 1.6380s + 0.09852}$	$\frac{-0.0003s + 0.0020}{s^2 + 2.4298s + 0.0651}$

O algoritmo do MPC apresentado no capítulo anterior é aplicado no processo da coluna depropanizadora a fim de controlar as variáveis “concentração de C3+” e “temperatura de topo”, manipulando as entradas do processo: “vazão de refluxo” e “vazão do fluido de aquecimento”, conforme Figura 3.2.

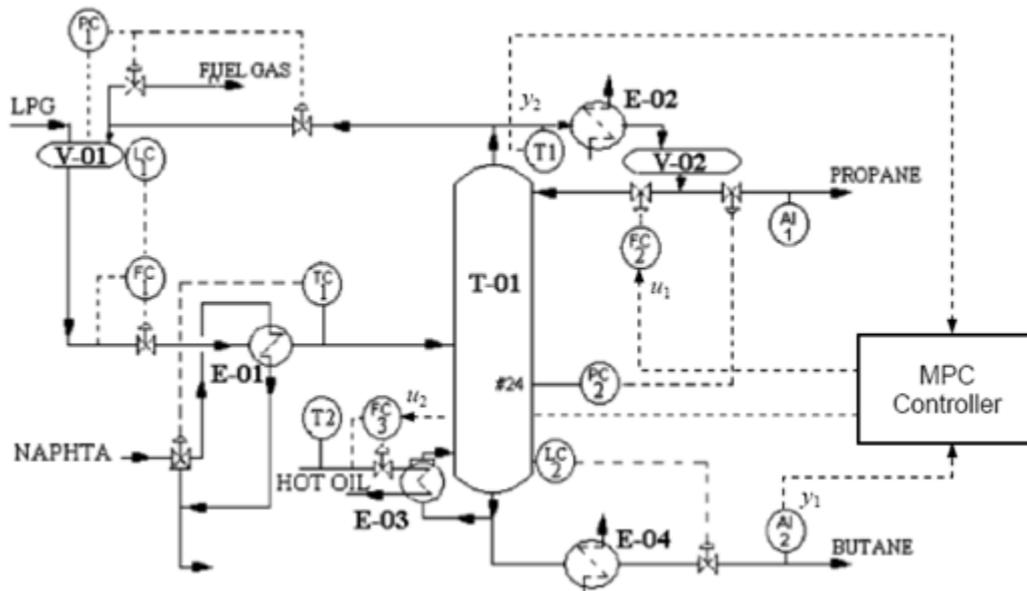


Figura 3.2 – Controlador Preditivo aplicado a coluna depropanizadora.
Fonte: Adaptado de PORFIRIO (2001).

O MPC tem em seu algoritmo o modelo do processo e utiliza-o para levar em conta todas as características significativas da dinâmica do processo no cálculo da lei de controle e prever o comportamento futuro das saídas, considerando o efeito das ações de controle (SOTOMAYOR *et al.*, 2009).

Os parâmetros de sintonia do controlador MPC estão listado na Tabela 3.2.

Tabela 3.2 - Parâmetros de Sintonia do MPC Tabela.

Parâmetros de sintonia do MPC	
Horizonte de predição (p)	60
Horizonte de controle (m)	2
Fator de supressão da controlada (w)	[1.3 1.2]
Fator de supressão das manipuladas (r)	[1.5 1.5]
Tempo de amostragem	1 min
Setpoint	[0.88 49.34]

Limites da manipulada (u_{\max})	[3250 2000]
Limites da manipulada (u_{\min})	[2800 1500]
Varição máxima da manipulada (Δu_{\max})	[10 10]
Fator de ponderação do termo quadrático da camada de otimização (Q_1)	[0.001 0.001]
Fator de ponderação do termo linear da camada de otimização (Q_2)	[500 -500]

3.1.1 - Resultados e discussão

Esta etapa apresenta as respostas do sistema às variações nos setpoints da concentração de C3+ e da Temperatura de Topo.

Primeiramente, foi alterado o setpoint da concentração de C3 + no Butano no instante 500s (de 0.88% para 0.95%) e no instante 1100s (de 0.95% para 0.9%). Como pode ser visto na Figura 3.3, o MPC respondeu bem às variações no setpoint corrigindo de imediato a variável de processo, sem causar overshoot. Já a Temperatura de Topo, mesmo não tendo o seu setpoint alterado, teve que ser corrigida pelo controlador MPC, uma vez que existe uma correlação forte entre as variáveis. O resposta do MPC também foi satisfatória, conforme apresentado na Figura 3.4.

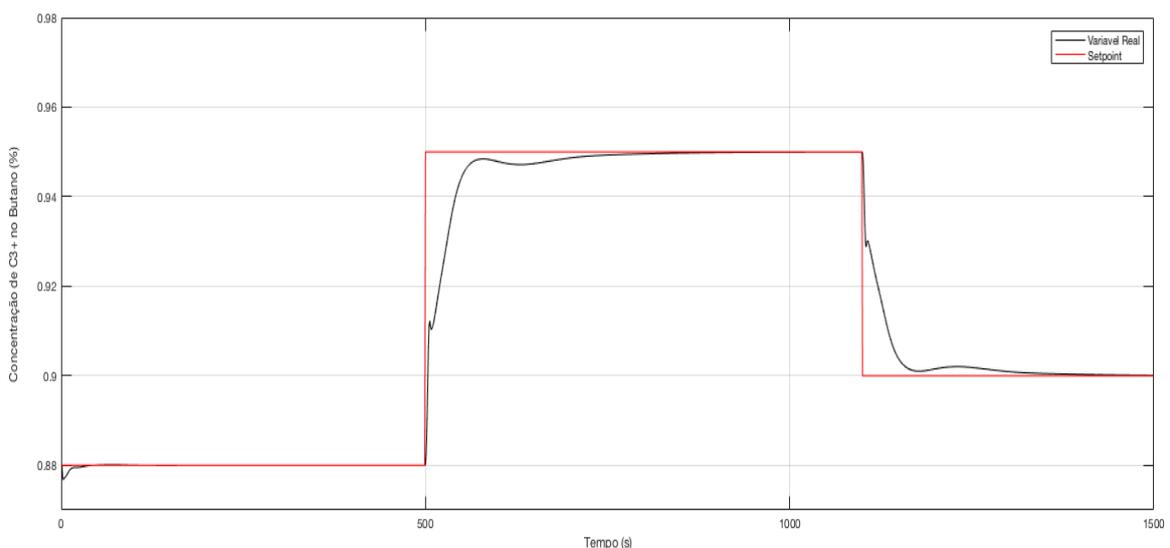


Figura 3.3 – Resposta do MPC a alteração do Setpoint da Concentração C3+ (Variável Controlada – Concentração de C3+ no Butano).

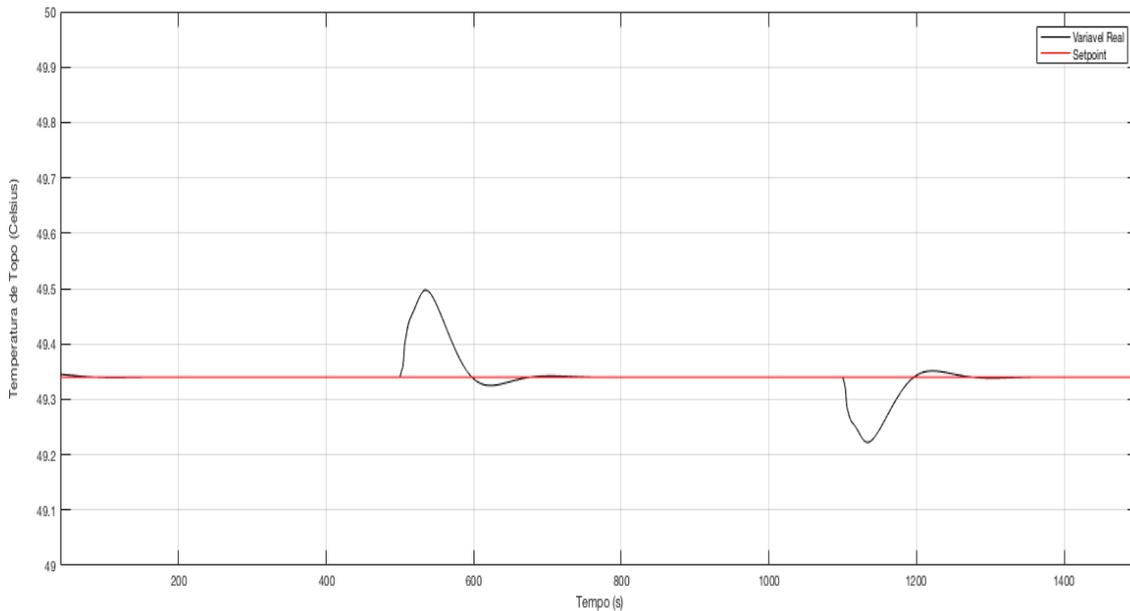


Figura 3.4 – Resposta do MPC a alteração do Setpoint da Concentração C3+ (Variável Controlada – Temperatura de Topo).

Em seguida, ainda para avaliar a performance do MPC, foi alterado o setpoint da Temperatura de Topo no instante 500s (de 49,34°C para 50,5°C) e no instante 1100s (de 50,5°C para 49°C), conforme figura .

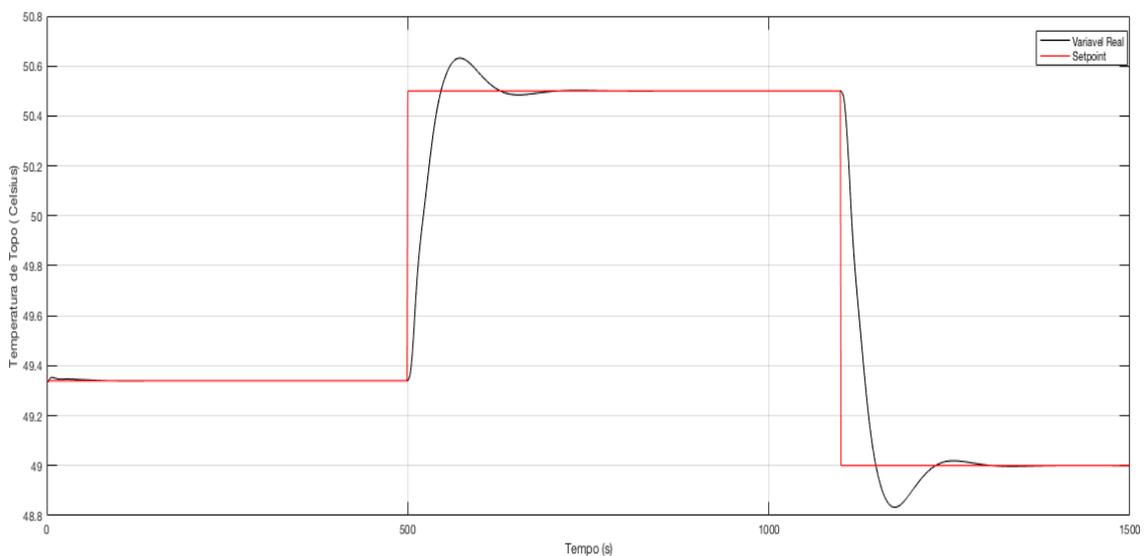


Figura 3.5 – Resposta do MPC a alteração do Setpoint da Temperatura de Topo (Variável Controlada – Temperatura de Topo).

O resultado apresentado na Figura 3.5 demonstra que o MPC está bem sintonizado e com boa capacidade de correção da variável de processo. Percebe-se nessa

resposta, a presença de um pequeno overshoot, entretanto o MPC consegue corrigir rapidamente sem perder a estabilidade do processo.

Por fim, da mesma forma que houve a oscilação da Temperatura de Topo durante o transiente provocado pela variação do setpoint da Concentração do C3+ na simulação anterior, houve, durante esta simulação, variação na composição de C3+ devido ao transiente provocado pela mudança de setpoint da Temperatura de Topo, conforme pode ser visto na Figura 3.6. Apesar do transiente o controlador MPC consegue corrigir a variável controlada e esta volta para o valor de referência.

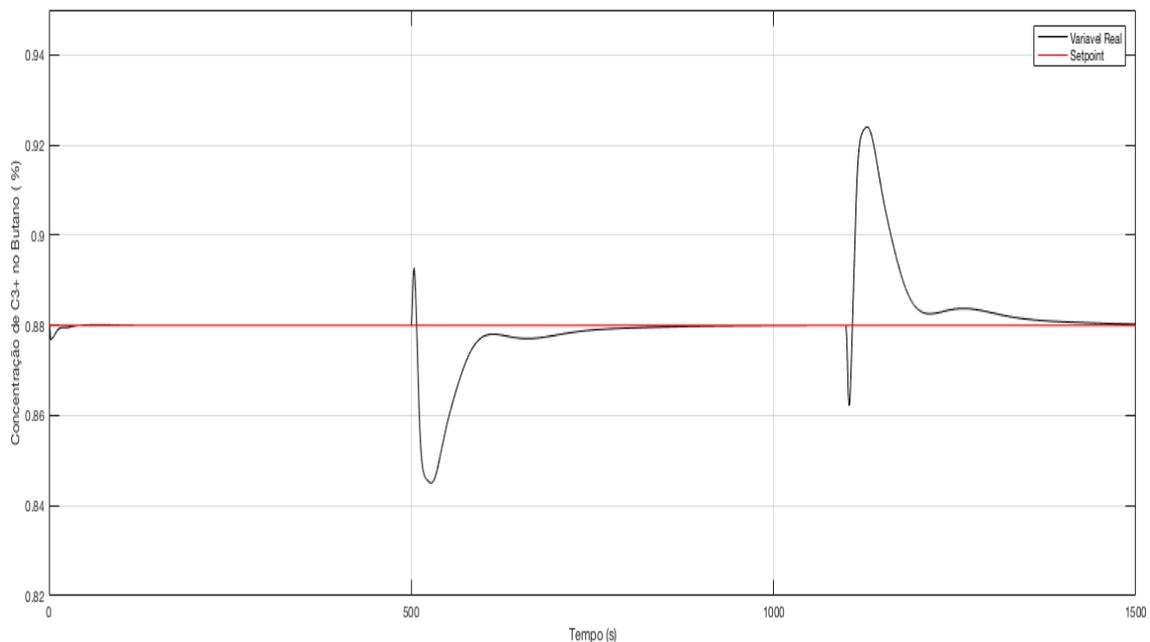


Figura 3.6 – Resposta do MPC a alteração do Setpoint da Temperatura de Topo (Variável Controlada – Concentração de C3+ no Butano).

3.2 - FILTRO DE KALMAN APLICADO A COLUNA DEPROPANIZADORA

Nesta seção é apresentada a metodologia utilizada para implementar o Filtro de Kalman, bem como avaliados os resultados desta implementação na coluna depropanizadora.

Antes de iniciar o projeto de implementação do FK, é verificado se o sistema é completamente observável. Para isso, inicialmente, se faz necessário encontrar as equações do sistema em tempo contínuo e em espaço de estado. Através da função *ss* do Matlab e utilizando as funções de transferências do processo descritas na Tabela 3.1, encontramos:

$$\begin{bmatrix} \dot{x}_1(t) \\ \dot{x}_2(t) \\ \dot{x}_3(t) \\ \dot{x}_4(t) \\ \dot{x}_5(t) \\ \dot{x}_6(t) \\ \dot{x}_7(t) \\ \dot{x}_8(t) \end{bmatrix} = \begin{bmatrix} -3.495 & -0.5902 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -1.638 & -0.3941 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.25 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & -2.699 & -0.8046 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.5 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -2.43 & -0.2604 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0.25 \end{bmatrix} \begin{bmatrix} x_1(t) \\ x_2(t) \\ x_3(t) \\ x_4(t) \\ x_5(t) \\ x_6(t) \\ x_7(t) \\ x_8(t) \end{bmatrix} + \begin{bmatrix} 0.0312 & 0 \\ 0 & 0 \\ 0.062 & 0 \\ 0 & 0 \\ 0 & 0.062 \\ 0 & 0 \\ 0 & 0.125 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} u_1(t) \\ u_2(t) \end{bmatrix} \quad (3.1)$$

$$\begin{bmatrix} y_1(t) \\ y_2(t) \end{bmatrix} = \begin{bmatrix} -0.007 & 0.0181 & 0 & 0 & 0.0011 & -0.04646 & 0 & 0 \\ 0 & 0 & -0.01816 & -0.07904 & 0 & 0 & -0.0024 & 0.064 \end{bmatrix} \begin{bmatrix} x_1(t) \\ x_2(t) \\ x_3(t) \\ x_4(t) \\ x_5(t) \\ x_6(t) \\ x_7(t) \\ x_8(t) \end{bmatrix} \quad (3.2)$$

A partir dessas equações, é usada a função *c2d* no Matlab para passar o sistema do domínio do tempo contínuo para o discreto, obtendo:

$$\begin{bmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \\ x_4(k+1) \\ x_5(k+1) \\ x_6(k+1) \\ x_7(k+1) \\ x_8(k+1) \end{bmatrix} = \begin{bmatrix} -0.00912 & -0.1506 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0.2551 & 0.8824 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.1766 & -0.1908 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.121 & 0.9697 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.02733 & -0.2617 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.1626 & 0.905 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.0804 & -0.0967 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.0929 & 0.9833 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \\ x_5(k) \\ x_6(k) \\ x_7(k) \\ x_8(k) \end{bmatrix} + \begin{bmatrix} 0.0079 & 0 \\ 0.0062 & 0 \\ 0.03026 & 0 \\ 0.00481 & 0 \\ 0 & 0.0203 \\ 0 & 0.0073 \\ 0 & 0.04645 \\ 0 & 0.0079 \end{bmatrix} \begin{bmatrix} u_1(k) \\ u_2(k) \end{bmatrix} \quad (3.3)$$

$$\begin{bmatrix} y_1(k) \\ y_2(k) \end{bmatrix} = \begin{bmatrix} -0.007 & 0.0181 & 0 & 0 & 0.0011 & -0.04646 & 0 & 0 \\ 0 & 0 & -0.01816 & -0.07904 & 0 & 0 & -0.0024 & 0.064 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \\ x_5(k) \\ x_6(k) \\ x_7(k) \\ x_8(k) \end{bmatrix} \quad (3.4)$$

O tempo de amostragem para obtenção do sistema discreto foi de 1 segundo.

Finalmente, é avaliado se o sistema dinâmico da coluna depropanizadora descrito pelas Equações 28 e 29 é completamente observável. Para isso, basta calcular a Matriz de Observabilidade e determinar seu *rank*. Através do comando *obsv* no Matlab, encontramos a matriz de observabilidade abaixo:

$$O = \begin{bmatrix} -0.0071 & 0.0181 & 0 & 0 & 0.0012 & -0.0465 & 0 & 0 \\ 0 & 0 & -0.0182 & -0.0790 & 0 & 0 & -0.0024 & 0.0640 \\ 0.0047 & 0.0170 & 0 & 0 & -0.0075 & -0.0424 & 0 & 0 \\ 0 & 0 & -0.0128 & -0.0732 & 0 & 0 & 0.0058 & 0.0632 \\ 0.0043 & 0.0143 & 0 & 0 & -0.0071 & -0.0364 & 0 & 0 \\ 0 & 0 & -0.0111 & -0.0685 & 0 & 0 & 0.0063 & 0.0616 \\ 0.0036 & 0.0120 & 0 & 0 & -0.0061 & -0.0311 & 0 & 0 \\ 0 & 0 & -0.0103 & -0.0643 & 0 & 0 & 0.0062 & 0.0599 \\ 0.0030 & 0.0100 & 0 & 0 & -0.0052 & -0.0265 & 0 & 0 \\ 0 & 0 & -0.0096 & -0.0604 & 0 & 0 & 0.0061 & 0.0583 \\ 0.0025 & 0.0084 & 0 & 0 & -0.0045 & -0.0226 & 0 & 0 \\ 0 & 0 & -0.0090 & -0.0567 & 0 & 0 & 0.0059 & 0.0568 \\ 0.0021 & 0.0070 & 0 & 0 & -0.0038 & -0.0193 & 0 & 0 \\ 0 & 0 & -0.0085 & -0.0533 & 0 & 0 & 0.0057 & 0.0552 \\ 0.0018 & 0.0059 & 0 & 0 & -0.0032 & -0.0165 & 0 & 0 \\ 0 & 0 & -0.0079 & -0.0501 & 0 & 0 & 0.0056 & 0.0538 \end{bmatrix} \quad (3.5)$$

Para que o sistema seja completamente observável, basta que o rank da matriz seja igual ao número de estados do sistema, neste caso, 8. O rank é a quantidade de colunas linearmente independente da matriz de observabilidade.

Utilizando a função *rank* do MATLAB, encontra-se que o rank desta matriz de observabilidade é de fato 8, o que implica que o sistema é completamente observável, e portanto, o Filtro de Kalman pode ser usado para estimar os estados do sistema.

Após confirmação da observabilidade do sistema, inicializamos o filtro com suas condições iniciais:

$$x(0) = [0\ 0\ 0\ 0\ 0\ 0\ 0\ 0]^T$$

$$y(0) = [0.88\ 49.34]^T$$

$$u(0) = [0\ 0]^T$$

$$P(0) = \begin{bmatrix} 10^{12} & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 10^{12} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 10^{12} & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 10^{12} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 10^{12} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 10^{12} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 10^{12} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 10^{12} \end{bmatrix}$$

$$Q(0) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$R(0) = \begin{bmatrix} 0.99 & 0 \\ 0 & 0.99 \end{bmatrix}$$

As matrizes Q e R são, respectivamente, as matrizes de ruído do modelo e da medição adicionados no sistema. A matriz P é a matriz de covariância do erro de estimação. Conforme seção anterior, a etapa de correção e atualização do Filtro de Kalman é composta por três equações, conforme abaixo:

$$K_k = \bar{P}_k C_k^T (R_k + C_k \bar{P}_k C_k^T)^{-1} \quad (3.6)$$

$$\hat{x}_k = \bar{x}_k + K_k (y_k - C_k \bar{x}_k) \quad (3.7)$$

$$\hat{P}_k = (I - K_k C_k) \bar{P}_k (I - K_k C_k)^T + K_k R_k K_k^T \quad (3.8)$$

Entretanto para efeito deste trabalho, precisaremos estimar a variável do processo e não, apenas, o estado. Dessa forma, segue abaixo equação implementada no algoritmo para estimativa da variável:

$$\hat{y}_k = C \hat{x}_k \quad (3.9)$$

3.2.1 - Resultados e discussão

A seguir são apresentados os resultados da implementação do Filtro de Kalman com o objetivo de estimar as variáveis controladas do processo da coluna depropanizadora: Concentração de C3+ no butano e Temperatura de Topo. O tempo de amostragem do Filtro de Kalman é de 1 segundo.

Na Figura 3.7 é apresentado o comportamento do estimador (Saída do FK) da concentração de C3+ no butano do em relação a variável de processo sem ruído (Variável Real). Percebe-se que o estimador (linha vermelha do gráfico) acompanha de forma satisfatória o dinâmica da variável de processo (linha preta do gráfico). A simulação foi feita em intervalo de tempo de 1500s, e o resultado foi satisfatório em todo esse intervalo.

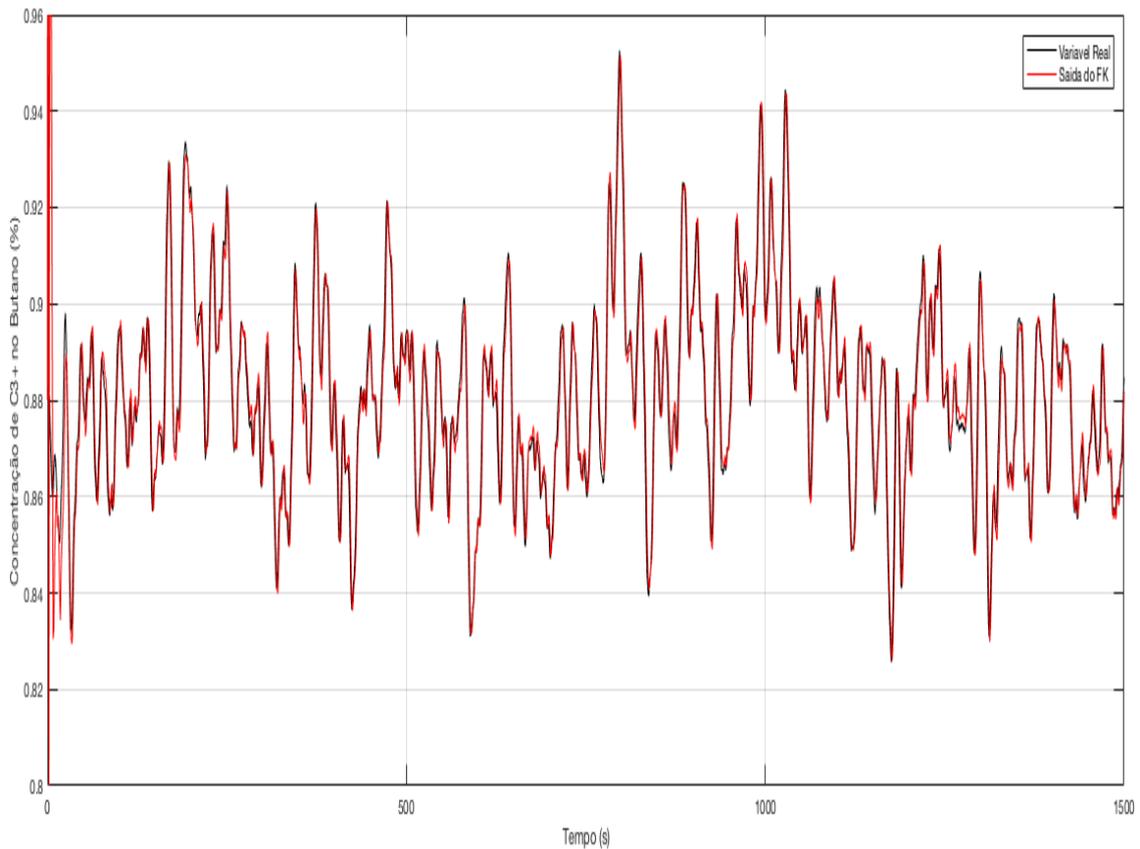


Figura 3.7 – Estimador FK da Concentração C3+ no Butano x Variável do Processo sem ruído.

Quanto a variável controlada, Temperatura de Topo, o comportamento do estimador (saída do FK) também acompanha a dinâmica da variável de processo sem ruído, mas o resultado apresenta certa disparidade, conforme pode ser visto na Figura 3.8. Este desvio deve ser causado pela inicialização feita, pela abordagem feita para estimar os parâmetros ou até por características do sistema. Apesar do exposto, o resultado do estimador FK apresenta resultado satisfatório para todo intervalo de tempo simulado, acompanhando bem a dinâmica da variável real.

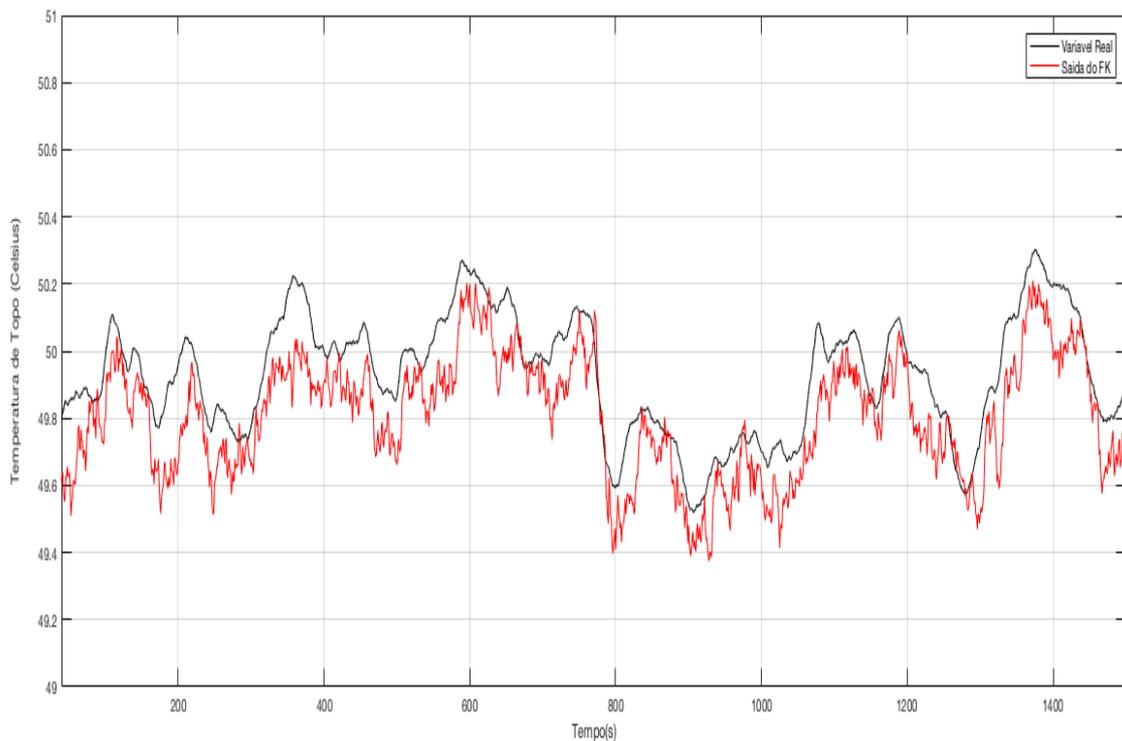


Figura 3.8 – Estimador FK da Temperatura de Topo x Variável do Processo sem ruído.

Para efeito de comparação e análise, as Figuras 3.9 e 3.10 demonstram o comportamento da variável do processo com ruído, variável do processo sem ruído (variável real) e o estimador da variável (Saída do FK). Percebe-se claramente que o estimador, para as duas variáveis, traz informações muito mais fidedigna e próxima da variável real que a variável ruidosa.

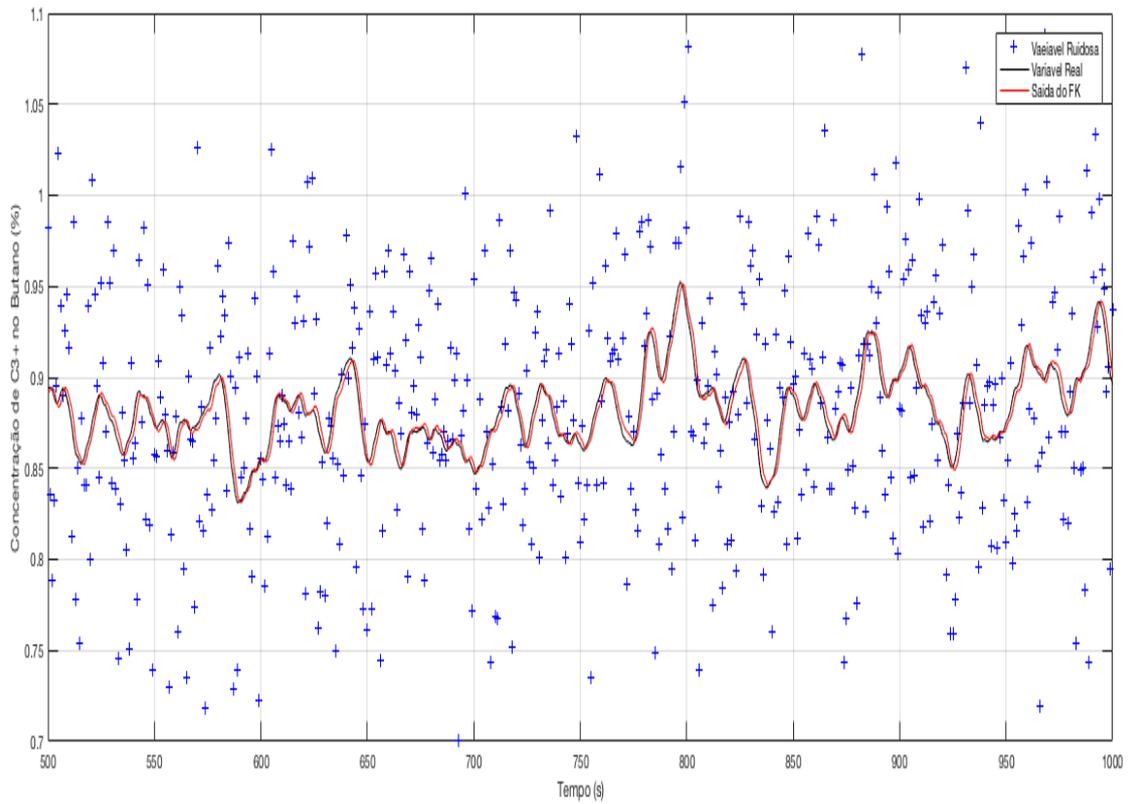


Figura 3.9 – Comparação entre variável com ruído, variável sem ruído e estimador FK (Concentração de C3+ no Butano).

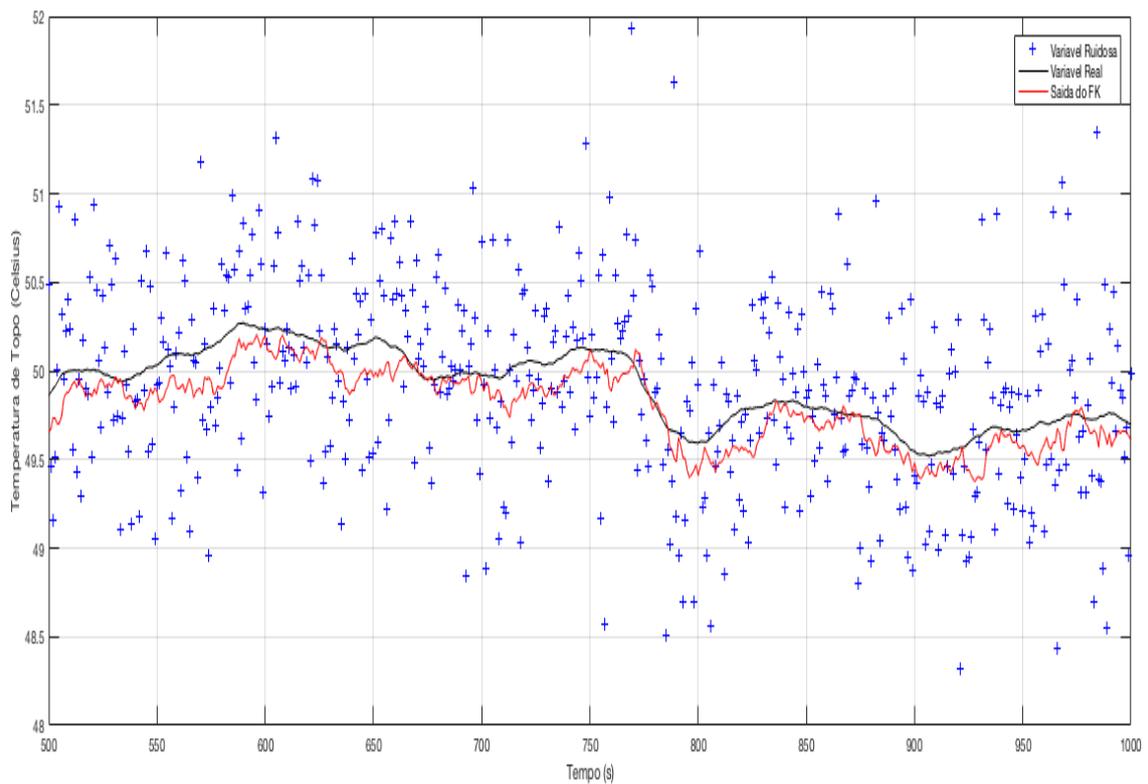


Figura 3.10 – Comparação entre variável com ruído, variável sem ruído e estimador FK (Temperatura de Topo).

Abaixo, na Figura 3.11, segue o comportamento dos oito estados do Filtro de Kalman projetado para estimar as variáveis de processo (coluna depropanizadora).

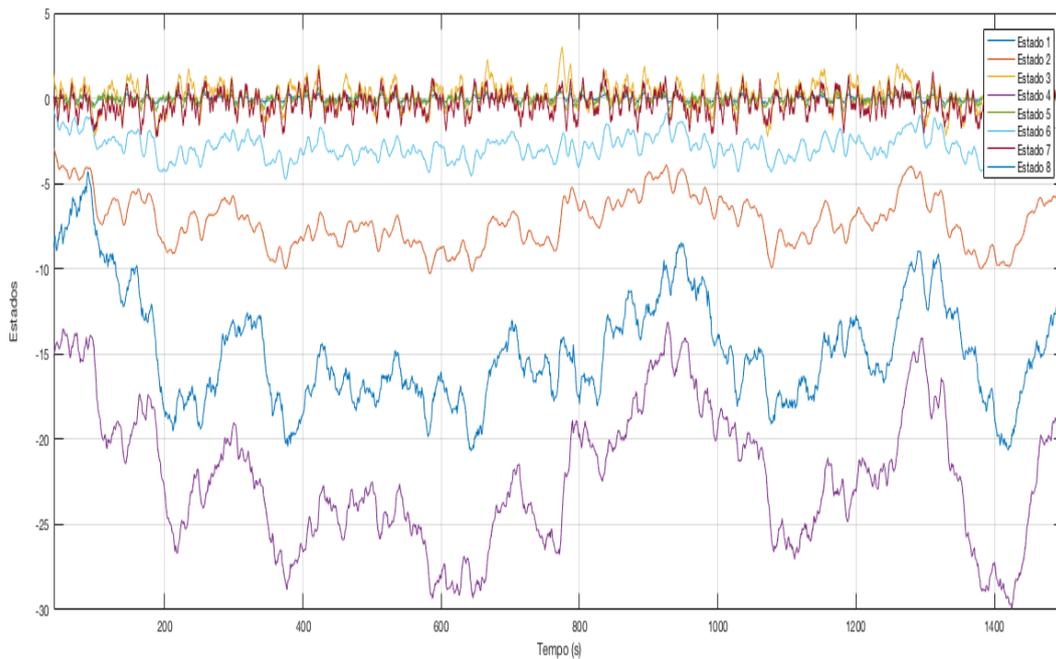


Figura 3.11- Estados estimados pelo FK.

3.3 - APRIMORAMENTO DO DESEMPENHO DO MPC APLICADO A COLUNA DEPROPANIZADORA

A implementação de Filtro de kalman em variáveis controladas pode aprimorar o desempenho dos sistemas de controle, a exemplo dos controladores PIDs e controle avançado, MPC. Na Figura 3.12 é apresentada o esquemático do sistema de controle com retroalimentação através do Filtro de Kalman.

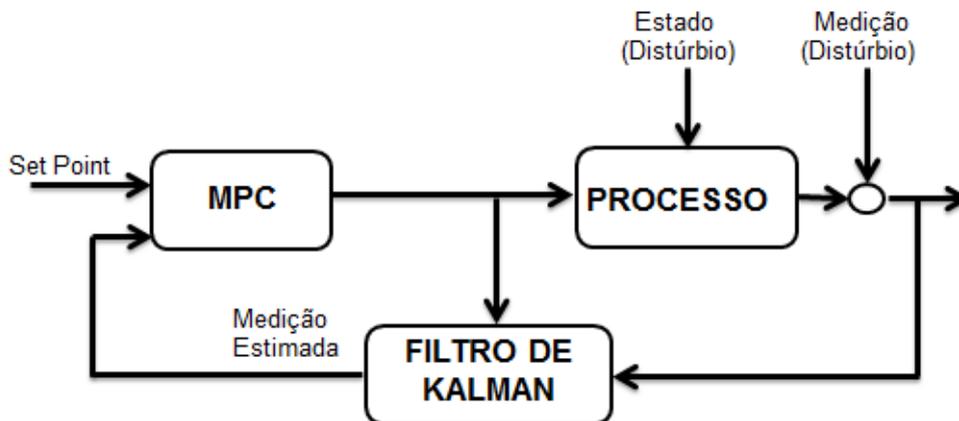


Figura 3.12 – Estimador FK e controle feedback aplicado ao MPC.

ABU-EL-ZEET *et al.* (2002) utilizaram um sistema de reconciliação de dados para o aprimoramento do desempenho de controladores do tipo MPC. Como estudo de caso, os autores utilizaram um sistema de dois tanques CSTH conectados em série submetido a um controlador do tipo MPC. Porém, os autores não utilizaram nenhum índice para especificar o grau de melhoria deste controlador, mostrando a melhoria somente de forma gráfica.

BAI *et al.* (2005) aplicaram um sistema de reconciliação baseado no algoritmo DDR preditor-corretor para a melhoria no desempenho de controladores PID e compararam esta técnica com o uso de filtros digitais. Para efeito de comparação, foram utilizados índices estatísticos tais como a integral do erro quadrado (ISE) e a integral da diferença do erro quadrático (ISDU). Os autores puderam concluir que utilizando o sistema DDR houve um aprimoramento no desempenho dos controladores PID, quando comparado a um sistema sem reconciliação e a sistemas utilizando filtros digitais.

3.3.1 - Resultados e discussão

Até então realizamos a simulação de dois sistemas (MPC e FK) de forma isolada. Nesta seção, faremos a realimentação do sistema de controle com a saída do estimador FK, variável controlada, em substituição a variável ruidosa, com o objetivo de avaliar a eficiência do MPC nesta nova condição. Os resultados das simulações são apresentados nas Figuras 3.13 a 3.16.

Inicialmente, o sistema foi simulado considerando o setpoint fixo (0.88 para concentração de C3+ no Butano e 50° C para Temperatura de Topo). Nos primeiros 500s desta, o controle preditivo atua considerando, como entrada, as variáveis ruidosas do processo, sem considerar a implementação do Filtro de Kalman. Após os 500s, é comutada a entrada do controlador, de forma a receber o sinal de saída do estimador Filtro de Kalman.

- Variáveis Controladas

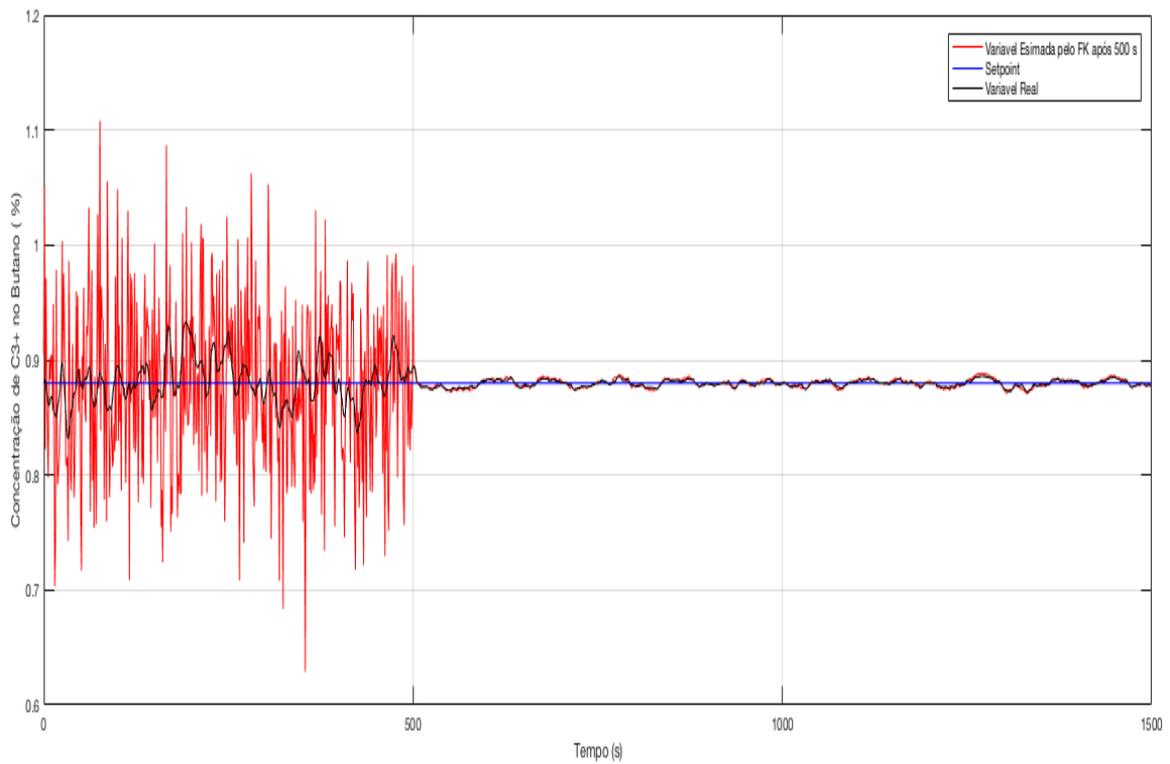


Figura 3.13 – Setpoint Fixo (0.88%)/ Retroalimentação pelo FK a partir do t=500s.
(Concentração de C3+ no Butano - y1).

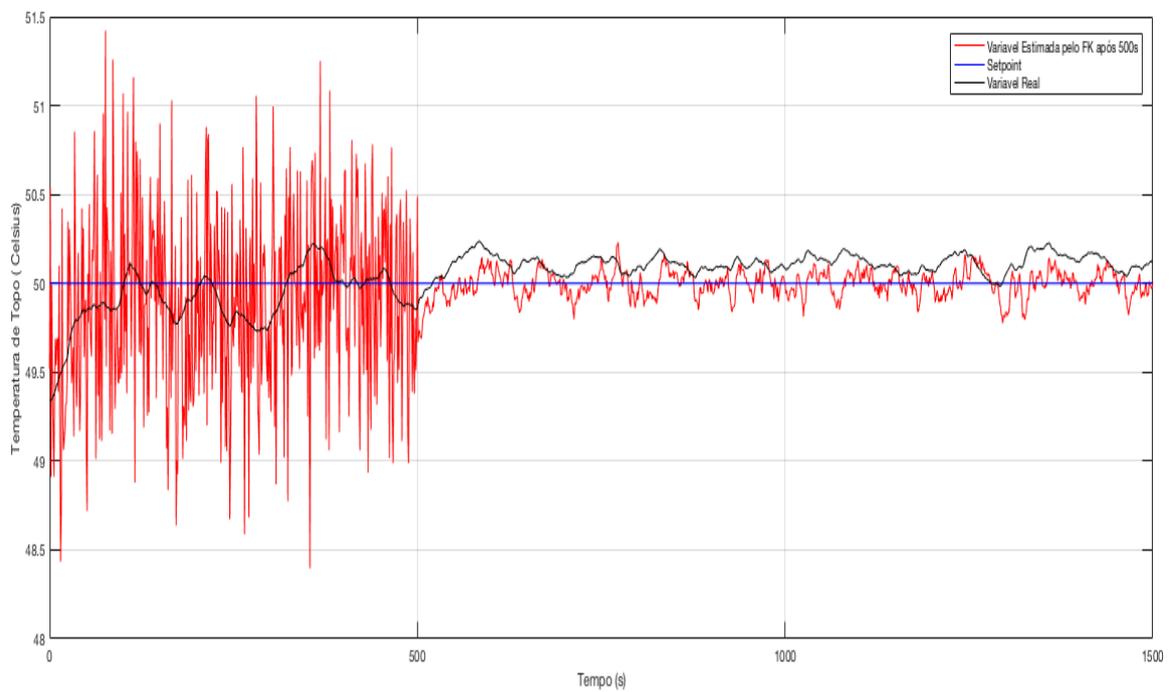


Figura 3.14 – Setpoint Fixo(49.24°C) / Retroalimentação pelo FK a partir do t=500s
(Temperatura de Topo - y2).

Tanto para a Concentração de C3+ no Butano quanto para a Temperatura de topo é evidente que a variabilidade em relação ao setpoint é reduzida acentuadamente após o controlador assumir a saída do FK , como entrada do controlador.

- Variáveis Manipuladas

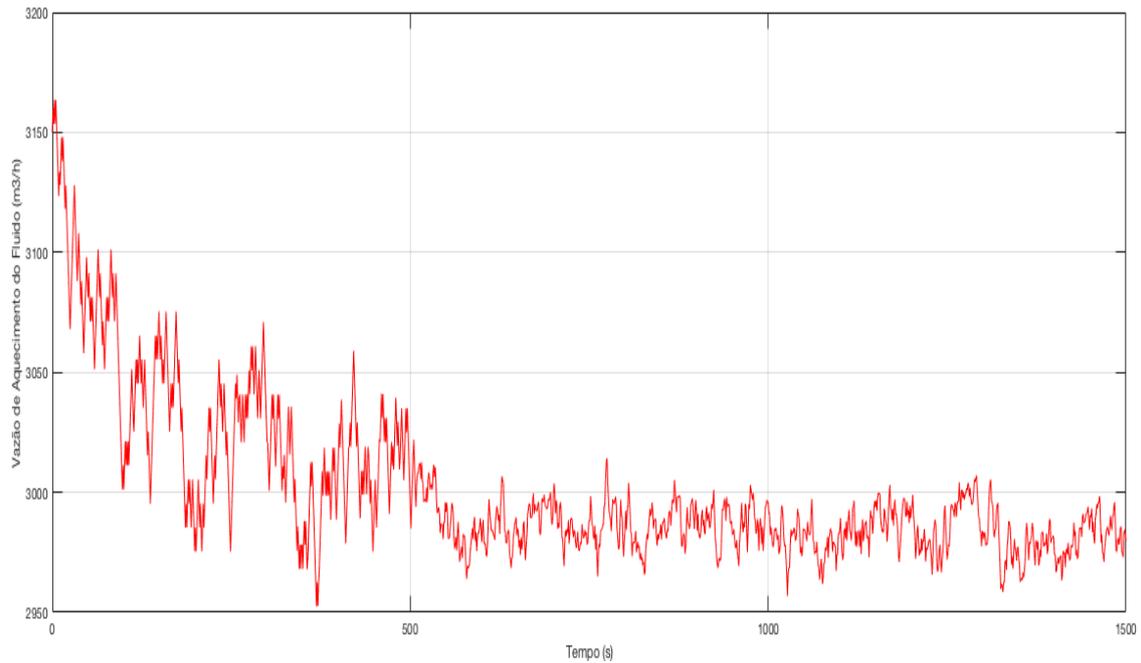


Figura 3.15 – Saída do Controlador MPC - u1 (Vazão de Fluido de Aquecimento).

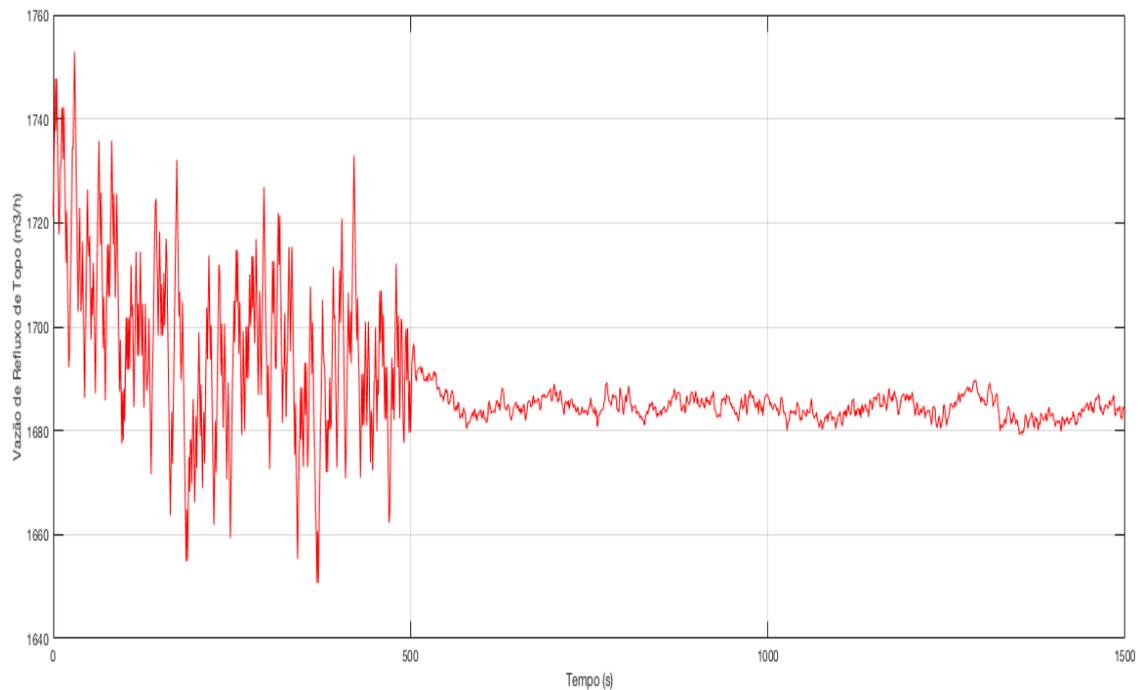


Figura 3.16 – Saída do Controlador MPC – u2 (Vazão de Refluxo de Topo).

Da mesma forma que acontece com as variáveis controladas, as duas variáveis manipuladas, saídas de controle, também apresentam comportamento mais estável após o controlador assumir a saída do FK ,como entrada do controlador.

Nas Figuras 3.17 a 3.24, são representados os resultados das simulações considerando as mesmas condições apresentadas anteriormente, ou seja, no instante $t=500s$, o sinal estimado pelo Filtro de Kalman passa a realimentar o sistema de controle. Adicionalmente, para efeito de verificação do desempenho do controle, no instante $t=1100s$, é realizada a variação do setpoint das variáveis controladas.

- a) Variação no setpoint da concentração de C3+ no Butano (0.88% para 0.95%) e manutenção do setpoint da Temperatura de Topo em 50 °C.

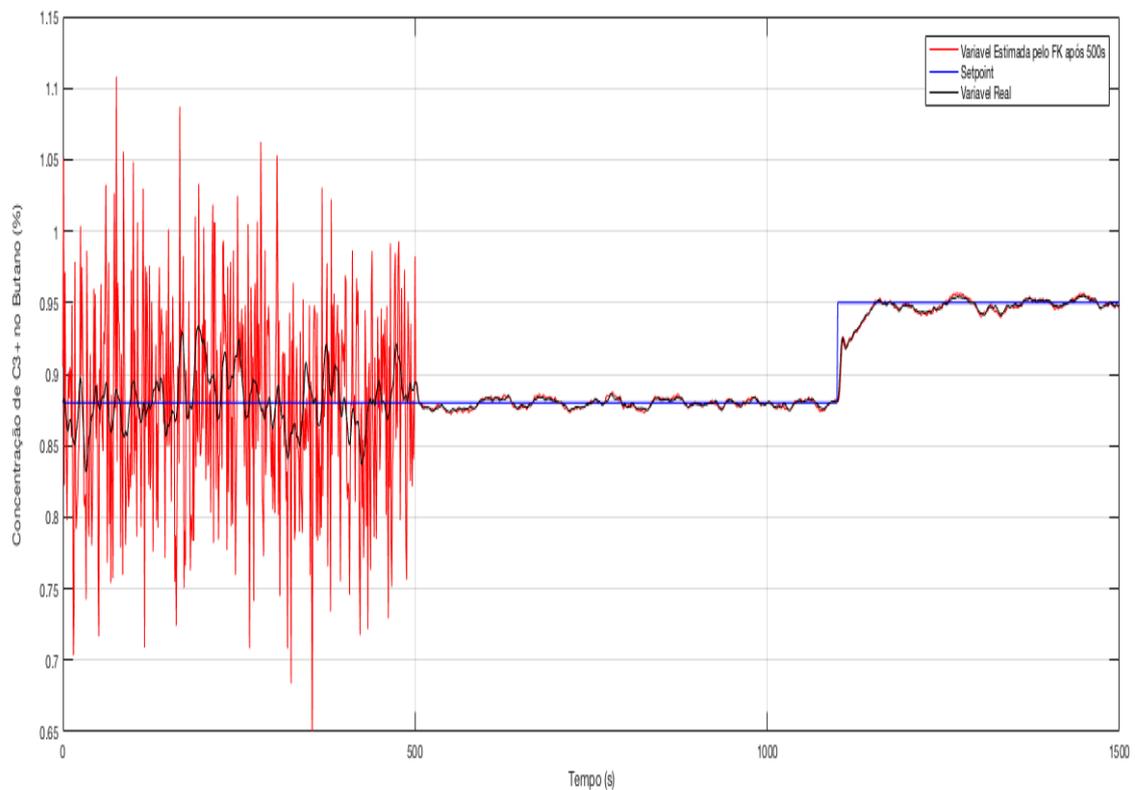


Figura 3.17 – Alteração de setpoint da Concentração C3+ no instante $t = 1100s$ (Concentração de C3+ no Butano - y_1).

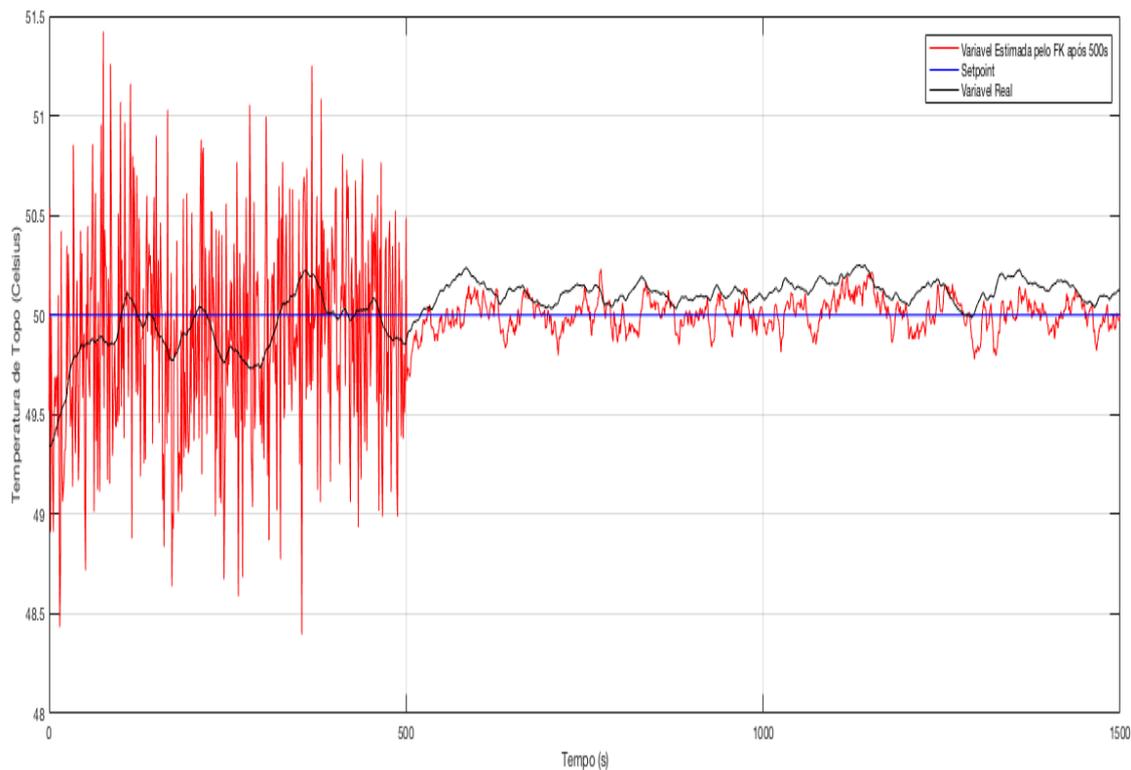


Figura 3.18 – Alteração de setpoint da Concentração C3+ no instante $t=1100s$ (Temperatura de Topo – y_2).

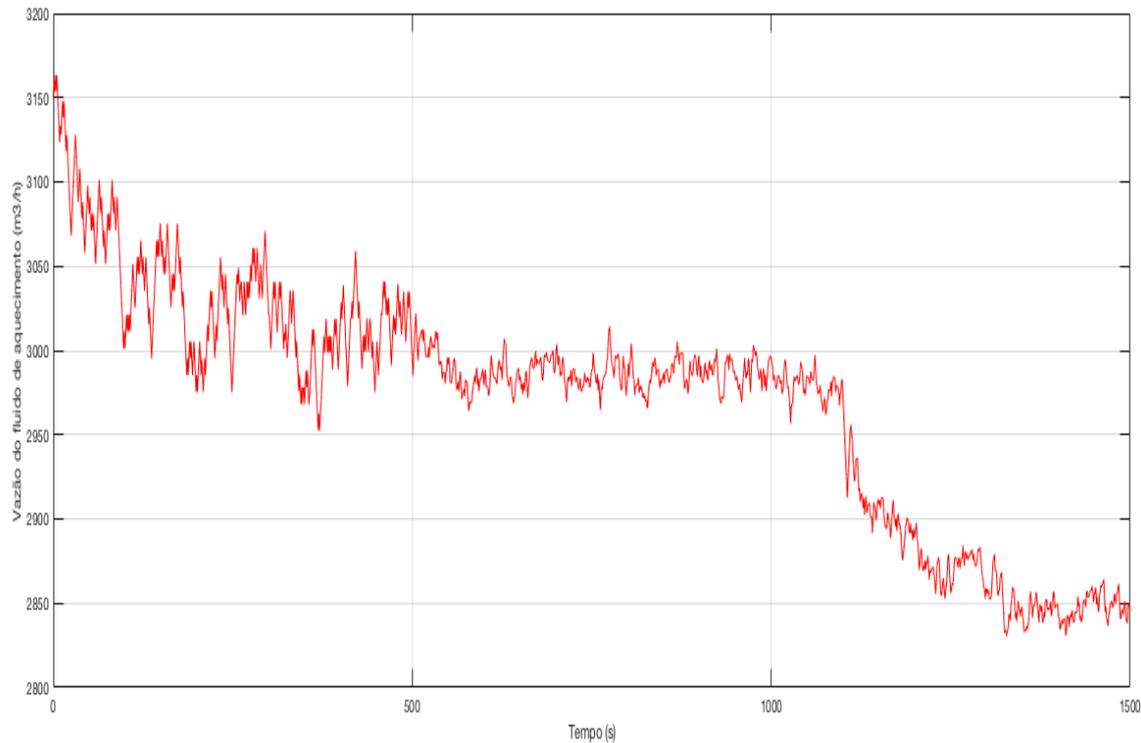


Figura 3.19 – Saída do Controlador MPC - u_1 (Vazão de Fluido de Aquecimento) / Alteração de setpoint da Concentração C3+ no instante $t=1100s$.

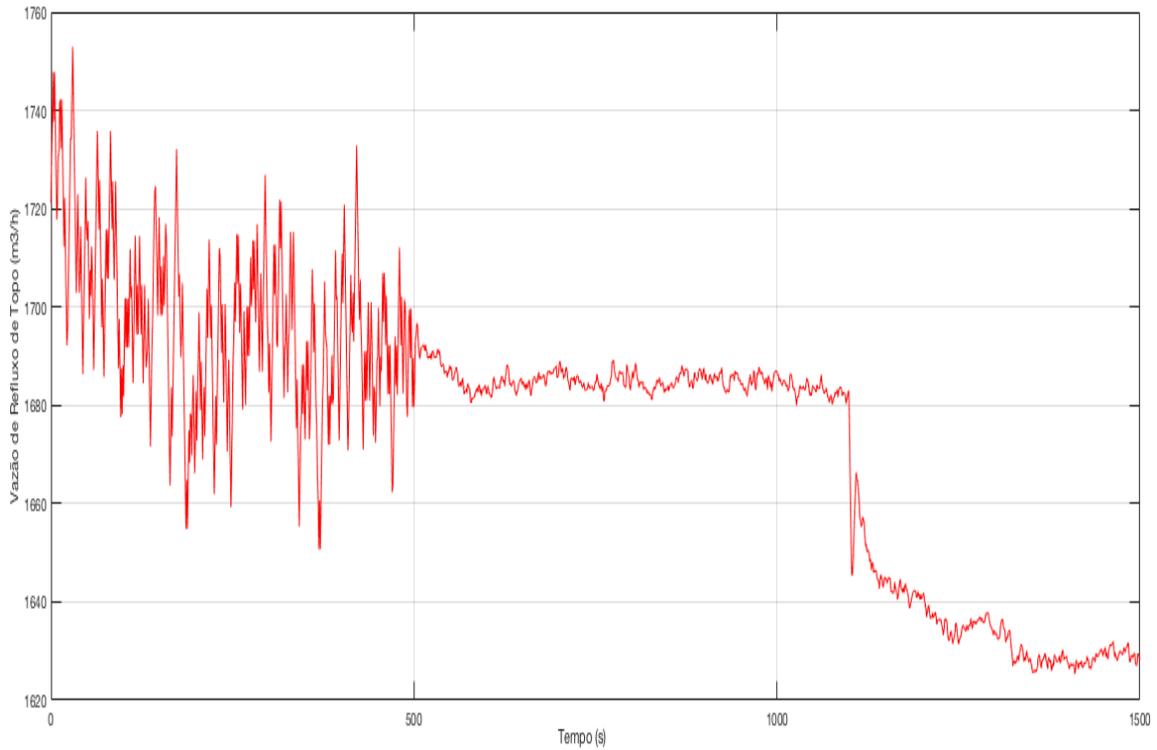


Figura 3.20 – Saída do Controlador MPC – u2 (Vazão de Refluxo de Topo) / Alteração de setpoint da Concentração C3+ no instante t =1100s.

b) Variação no setpoint da Temperatura (50°C para 49°C) e manutenção no setpoint da concentração de C3+ no Butano (0.88%)

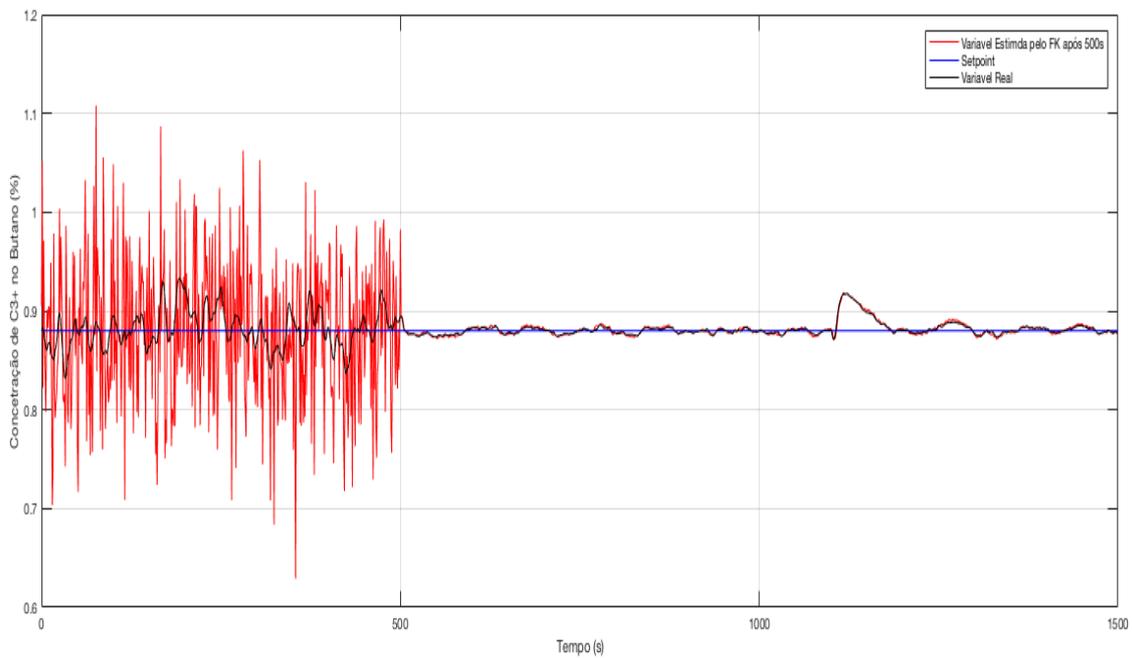


Figura 3.21 – Alteração de setpoint da Temperatura de Topo no instante t =1100s (Concentração de C3+ no Butano - y1).

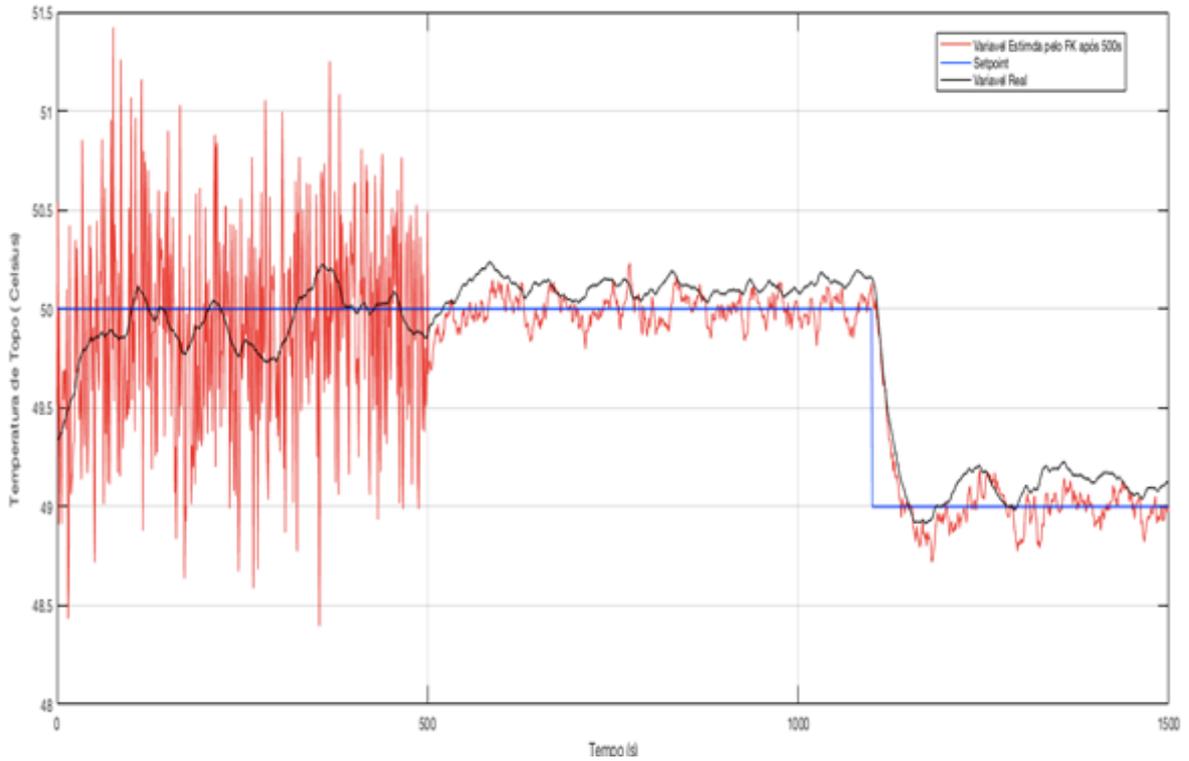


Figura 3.22 – Alteração de setpoint da Temperatura de Topo no instante $t = 1100s$ (Temperatura de Topo – y_2).

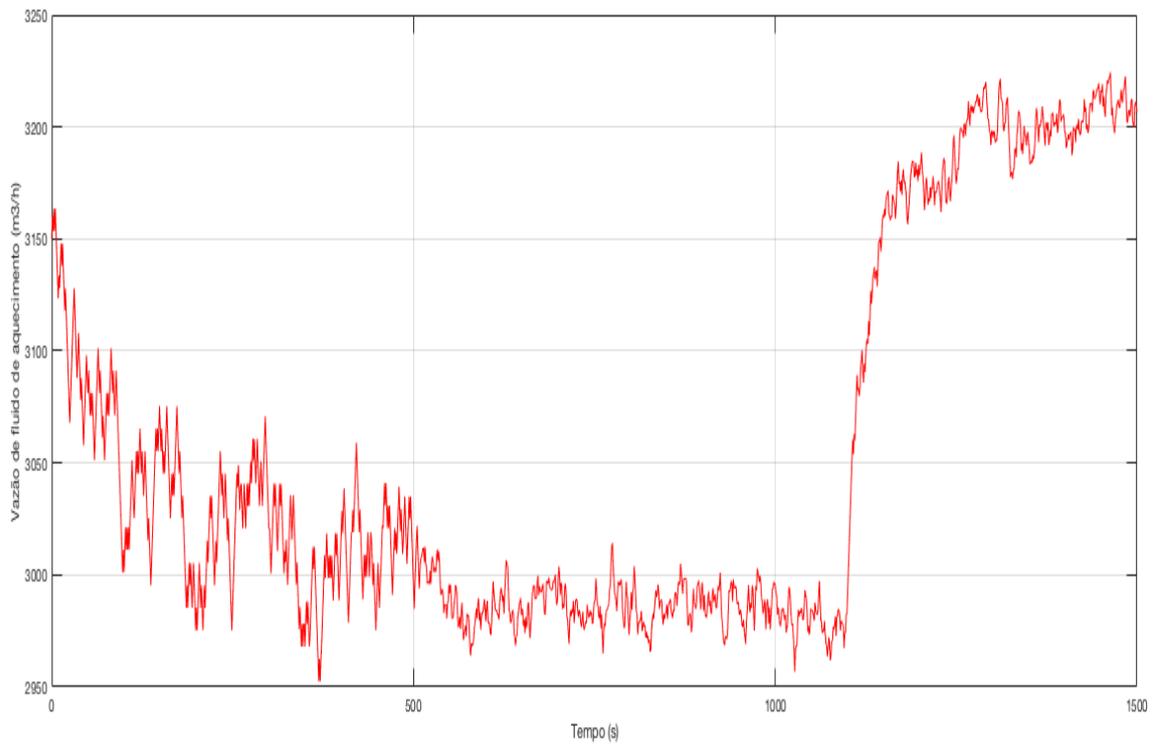


Figura 3.23 – Saída do Controlador MPC - u_1 (Vazão de Fluido de Aquecimento)/ Alteração de setpoint da Temperatura de Topo no instante $t = 1100s$.

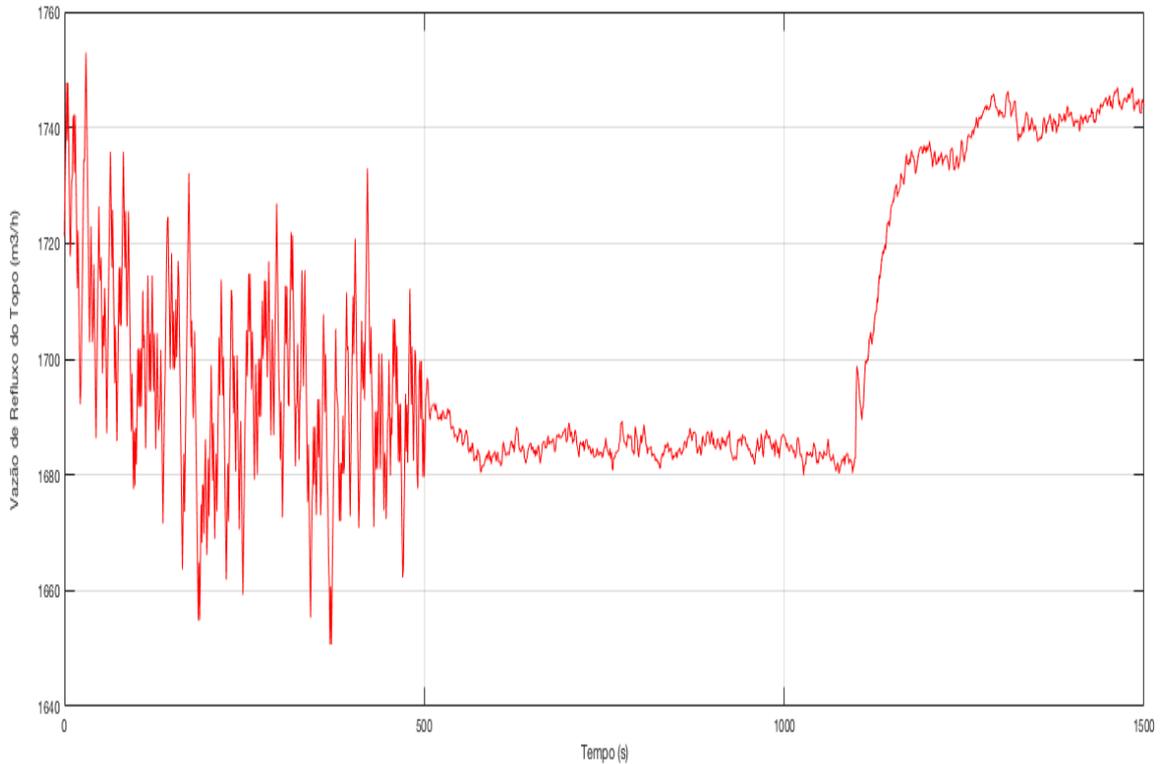


Figura 3.24 - Saída do Controlador MPC – u2 (Vazão de Refluxo de Topo) / Alteração de setpoint da Temperatura de Topo no instante t =1100s.

Os resultados apresentados nas Figuras 3.17 a 3.24 demonstram, de forma visual, que o controlador preditivo multivariável, MPC, após receber a variável estimada pelo FK tem uma melhoria evidente na performance do controlador. Outra evidência dos resultados acima apresentado é a capacidade da garantia da estabilidade de processo, mesmo com alteração no setpoint e forte interação entre as variáveis controlada.

De forma a avaliar quantitativamente o desempenho do controlador após a utilização do Filtro de Kalman foi utilizado como índice de desempenho o erro médio quadrático (EQM).

$$EQM = \frac{1}{N} \sum_{k=0}^N (\hat{y}_k - y_k)^2 \quad (3.10)$$

a) Análise do erro médio quadrático entre a variável controlada e o setpoint.

Para avaliar o comportamento do controle MPC ficou definido um intervalo para análise de 400 segundos, nos quais os 200s iniciais (de 300s a 500s) a entrada do controlador preditivo é a variável ruidosa, sem o tratamento através do Filtro de Kalman, e os 200s finais (de 500s a 700s) a entrada passa a ser o resultado do estimador

FK. Foram realizadas as análises para as duas variáveis de processo (Concentração de C3+ no Butano - y_1 e Temperatura de Topo - y_2), conforme abaixo.

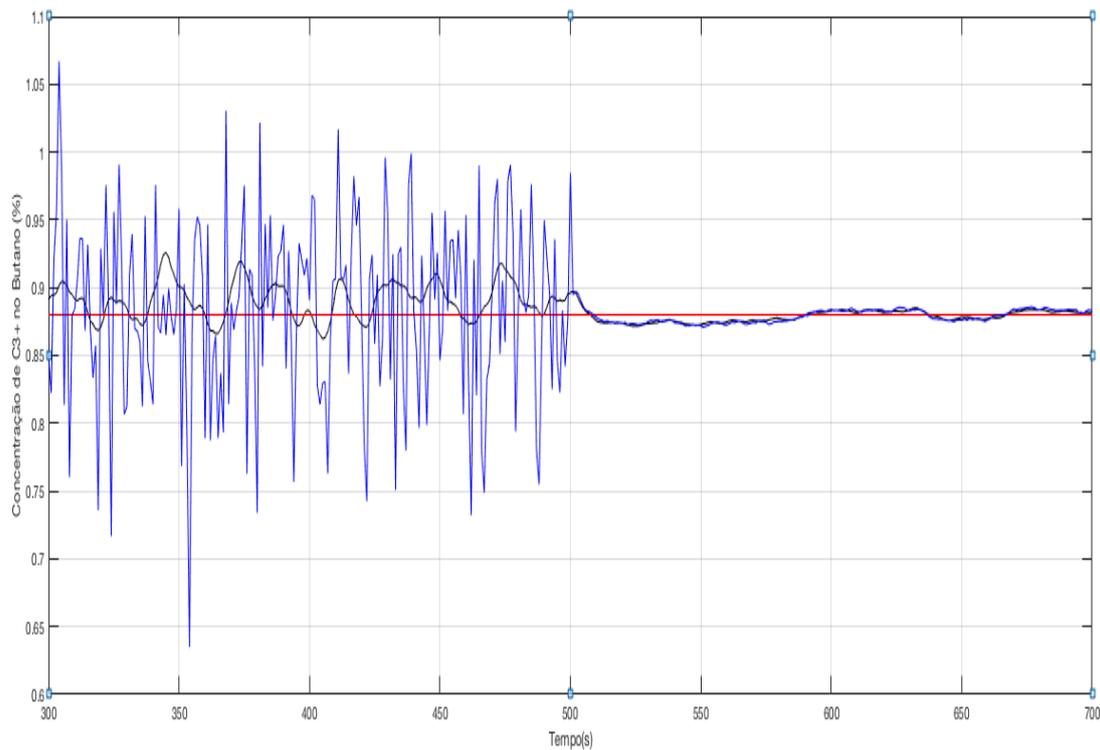


Figura 3.25 – Avaliação do desempenho do MPC (Concentração de C3+ no Butano - y_1 e Setpoint fixo = 0.88).

Tabela 3.3 - EQM (Concentração de C3+ no Butano - y_1 e Setpoint fixo = 0.88).

<i>EQM (Variável Controlada x Setpoint)</i>	<i>Concentração de C3+ no Butano (y_1)</i>
Variável Ruidosa e Setpoint – Intervalo (de 300s a 500s)	EQM = 4.7e-03
Variável Estimada e Setpoint – Intervalo de 500s a 700s =	EQM = 7.9629e-05

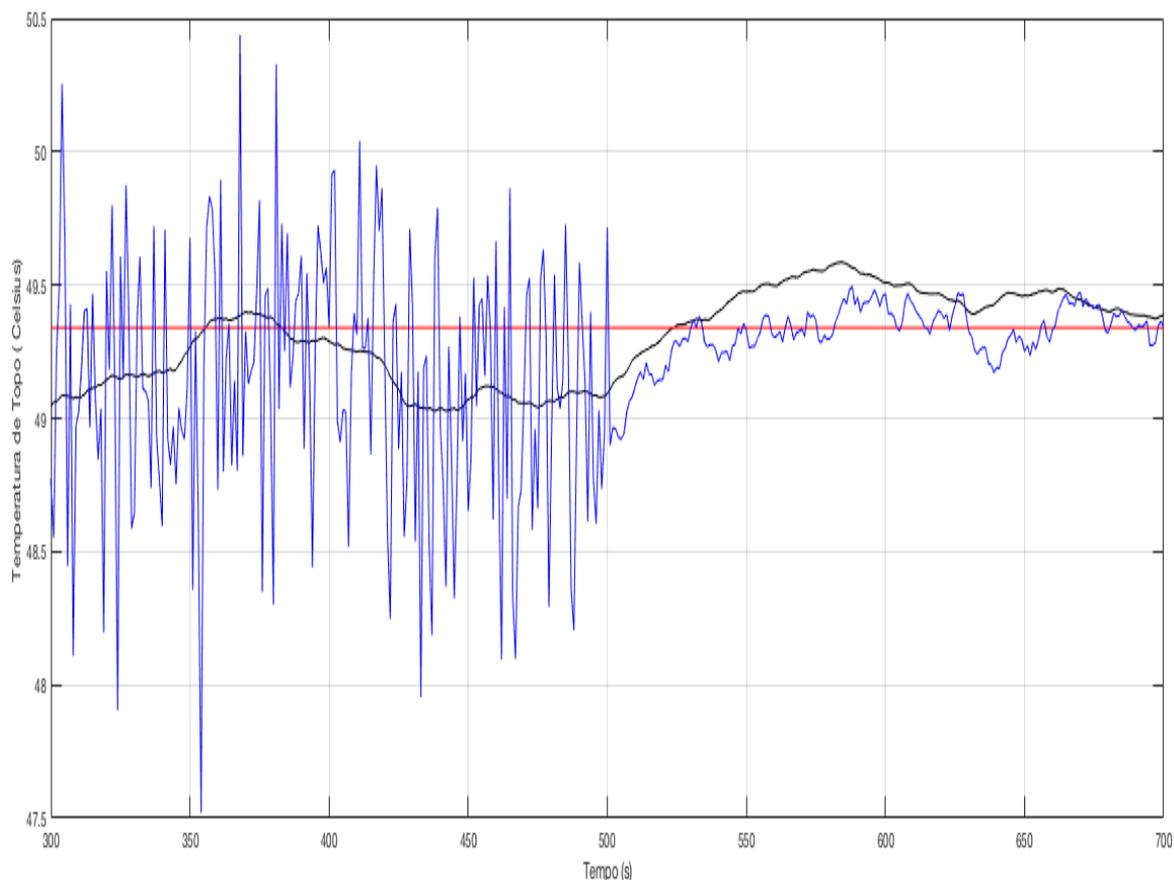


Figura 3.26 – Avaliação do desempenho do MPC (Temperatura de Topo – y_2 e “Setpoint” fixo = 49.34).

Tabela 3.4 - EQM (Temperatura de Topo – y_2 e Setpoint fixo = 49.34).

<i>EQM (Variável Controlada x Setpoint)</i>	<i>Temperatura de Topo (y_2)</i>
Variável Ruidosa e Setpoint – Intervalo (de 300s a 500s)	EQM = 0.2869
Variável Estimada e Setpoint – Intervalo de 500s a 700s =	EQM = 0.0143

Para as duas variáveis controladas, o valor do erro quadrático médio reduziu consideravelmente quando a entrada do controlador passou ser a variável estimada pelo FK. No caso da variável controlada Concentração de C3+ no Butano a redução do EQM foi aproximadamente de 59 vezes, já para a Temperatura de Topo a redução foi de aproximadamente de 20 vezes.

- b) Análise do erro médio quadrático entre a saída da camada de otimização estacionária do controlador preditivo (“Targets”) e a saída do controle MPC.

O controlador MPC implementado neste trabalho possui duas camadas de otimização, conforme apresentado no capítulo 2. Na camada de otimização estacionária é solucionado um problema de otimização e uma das suas saídas é o valor calculado do “targets”. Esse valor é enviado para a camada de otimização que leva em conta a dinâmica do processo e serve como referência para saída desta camada. Em condições normais e sistemas de controle bem projetados a saída da camada dinâmica do MPC acompanha bem os valores calculados de “targets”.

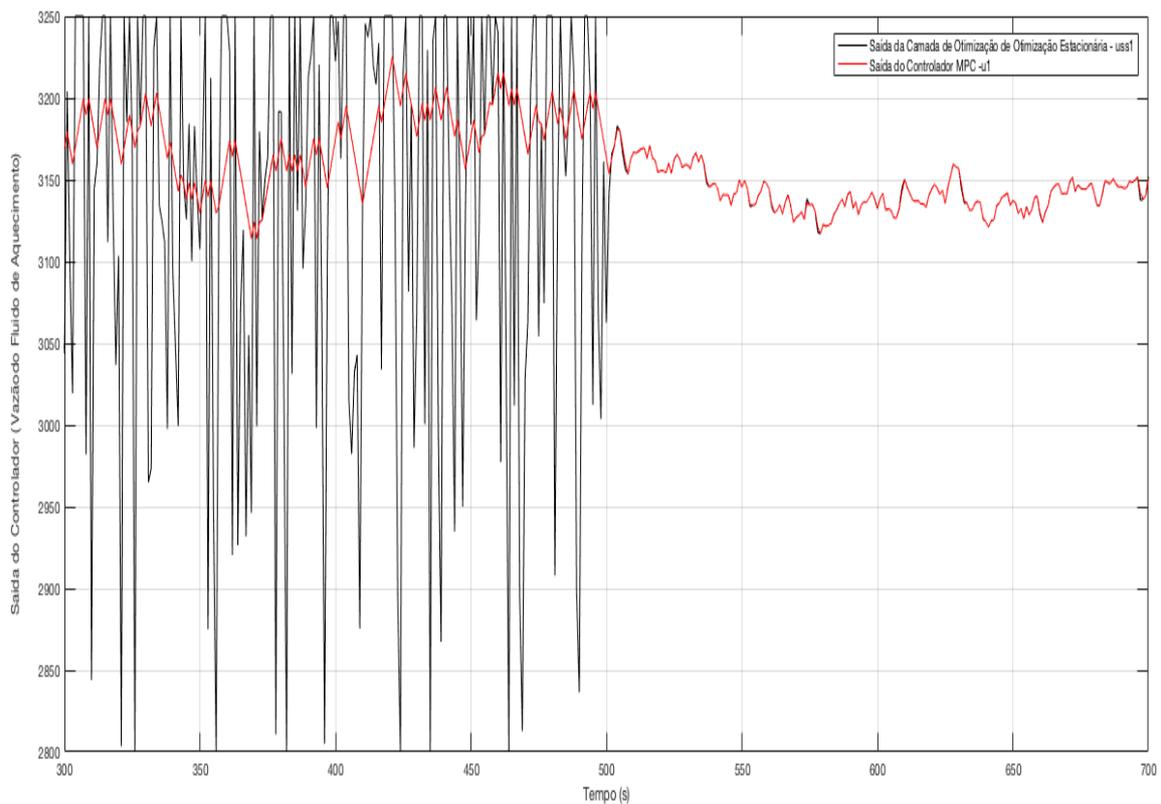


Figura 3.27 – Avaliação do desempenho do MPC. Targets e Saída do Controlador - (Vazão do Fluido de Aquecimento – $u1$).

Tabela 3.5 – EQM Targets e Saída do Controlador (Vazão do Fluido de Aquecimento).

<i>EQM</i> (<i>Targets</i> x <i>Saída do MPC</i>)	<i>Vazão do Fluido de Aquecimento (u1)</i>
Targets e Saída do MPC – Intervalo (de 300s a 500s)	EQM = 1.9071e+04

Targets e Saída do MPC –
Intervalo de 500s a 700s) =

EQM =52.8712

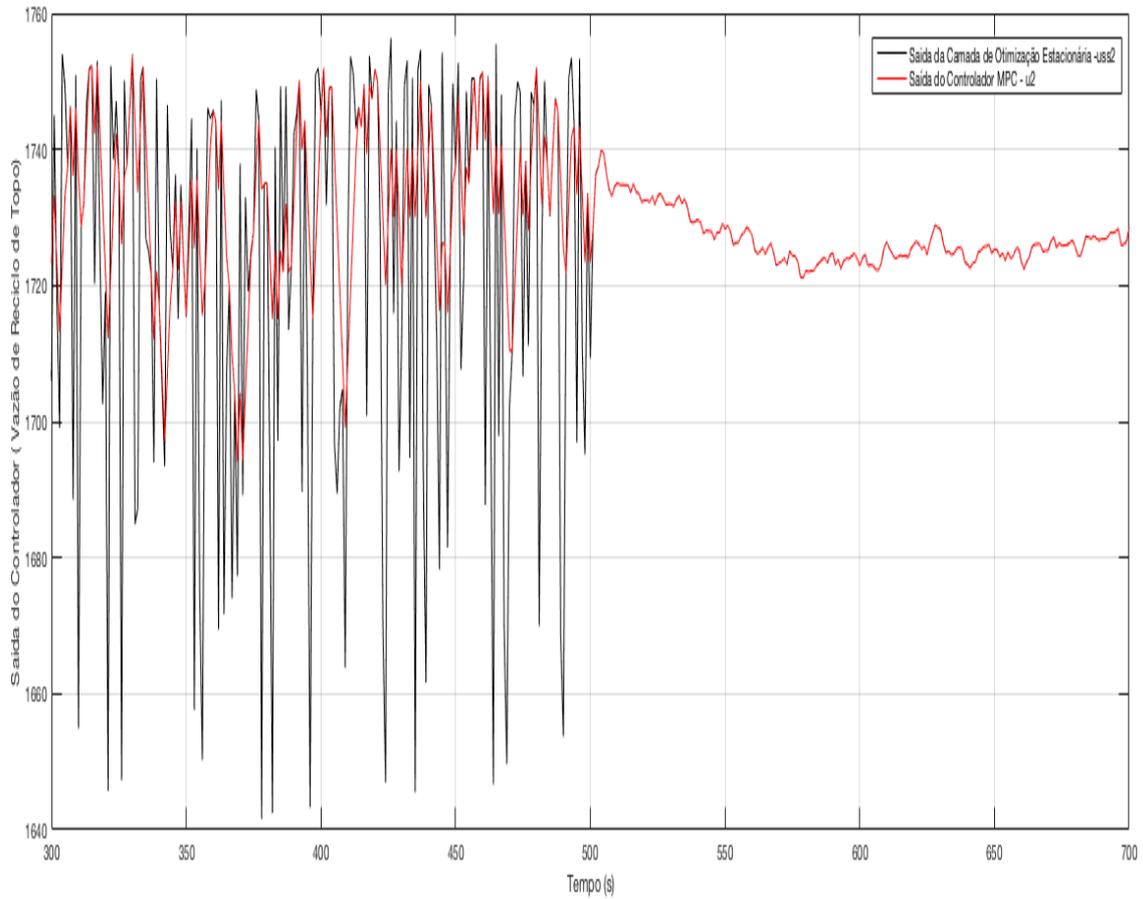


Figura 3.28 – Avaliação do desempenho do MPC/Targets e Saída do Controlador - (Vazão de Reciclo de Topo – u2).

Tabela 3.6 - EQM Targets e Saída do Controlador (Vazão de Reciclo de Topo).

<i>EQM</i> <i>(Targets x Saída do MPC)</i>	<i>Vazão de Reciclo de</i> <i>Topo (u2)</i>
Targets e Saída do MPC – Intervalo (de 300s a 500s)	EQM = 833.7303
Targets e Saída do MPC – Intervalo de 500s a 700s) =	EQM =0.9864

Da mesma forma que aconteceu a redução do EQM entre a entrada do controlador e o setpoint, quando a entrada do controlador passou ser a variável estimada pelo FK, o resultado do EQM entre os valores dos Targets e a saída da camada dinâmica, ou seja do controlador, também reduziu consideravelmente. Para a saída do controlador u1 (Vazão do Fluido de Aquecimento) e os Targets houve uma redução de aproximadamente 360 vezes, já para a saída do controlador u2 (Vazão de Reciclo de Topo) a redução foi de aproximadamente 845 vezes.

CAPÍTULO 4

CONCLUSÕES E SUGESTÕES

4.1 - CONCLUSÕES E SUGESTÕES

A linha de pesquisa desse trabalho teve como objetivo melhorar o desempenho do controlador preditivo multivariável, a partir da implementação do Filtro de Kalman junto às variáveis controladas (Concentração de C3+ no Butano e Temperatura de Topo) e posterior realimentação ao sistema de controle.

Primeiramente, foi implementado o controlador preditivo ao processo e avaliada sua performance. Em seguida, foi implementado o Filtro de Kalman e avaliado seu desempenho em malha aberta. Os resultados alcançados demonstraram a capacidade do Filtro de Kalman em reduzir com eficácia o erro aleatório, presente nos processos de medição das variáveis.

Depois da verificação do desempenho do Filtro de Kalman, foi efetuada a realimentação da saída deste ao controlador MPC, a fim de aumentar a eficiência deste.

Considerando a análise numérica, através do uso de indicador de desempenho (EQM), bem como avaliação gráfica das respostas do processo, foi observado um incremento considerável no desempenho do MPC.

Uma recomendação para trabalhos futuros é o uso de outras técnicas propostas na literatura, tais como: a Transformada *Wavelet*; Redes Neurais Artificiais e Análise de Componentes Principais em substituição ao Filtro de Kalman para efeitos de comparação.

Além disso, sugere-se ser feita a quantificação em redução de custos associado a implementação em melhoria da performance do sistema de controle, tal como a implementada neste trabalho.

Por fim, recomenda-se a aplicação do sistema de estimação de parâmetros, Filtro de Kalman, na aplicação real da Refinaria RPBC, a fim de verificar a sua eficiência e melhoria do desempenho do MPC existente.

REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, L. B. **Estudos da utilização do filtro de kalman para auto localização.** Dissertação de Mestrado/Universidade do Porto, 2008.

ABU-EL-ZEEET Z.H; ROBERTS, P D. Enhancing model predictive control using dynamic data reconciliation. American Institute of Chemical Engineers. **AIChE Journal**, v. 48, n. 2, p. 324, 2002.

AGUIRRE, L. A. **Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais.** 2a ed. Editora UFMG, Belo Horizonte, 2007.

BAI, S.; MCLEAN, D. D.; THIBAUT, J. Enhancing controller performance via dynamic data reconciliation. **The Canadian Journal of Chemical Engineering**, v. 83, n. 3, p. 515-526, 2005.

DA SILVA, G. M. A. **Reconciliação Dinâmica de dados baseada em estimadores em uma malha de controle MPC.** Dissertação de Mestrado/Universidade Federal de Sergipe, 2017.

ENGELL, S. Feedback control for optimal process operation. **Journal of Process Control**, 17(3): 203-219, 2007.

FARIA, M. C.P de. Aplicação do filtro de Kalman para a estimação de estados em um problema de rastreamento. **INPE-Instituto Nacional de Pesquisas Espaciais**, 2010. Disponível em: <http://mtcm16.sid.inpe.br/col/sid.inpe.br/marciana/2004/09.20.14.41/doc/aplica%e7%e3o%20do%20filtro%20de%20Kalman.pdf/>. Acesso em: 18 de dezembro de 2018.

GARCIA, C.E.; PRETT, D.M.; MORARI, M.; **Model predictive control - Theory and practice - A survey.** Automatica, 1989.

GOMES, C. F.; **Re-identificação em malha fechada de uma Planta de Separação de com Controle Preditivo MPC.** Graduação em Engenharia Elétrica /Universidade Federal de Sergipe, 2009.

GREWAL, M.S. and ANDREWS, A.P. **Kalman Filtering Theory and Practice Using MATLAB.** 4th Edition, John Wiley & Sons Inc., New York, 2014.

JUNIOR, S. L. S. **Aplicação de filtro de kalman para filtragem de sinais da rede elétrica.** Graduação em Engenharia Elétrica /Universidade Estadual de Londrina, 2016.

KALMAN, R. A new approach to linear filtering and prediction problems. **Transactions of the ASME Journal of Basic Engineering**, no.82, pp.35-45, 1960

KALMAN, R. BULCY R. S. New results in linear filtering and prediction theory. **Transactions of the ASME Journal of Basic Engineering**, no.83, pp.95-108, 1961

KASSMANN, D.E. BADGWELL, T.A. Robust steady-state target calculation for model predictive control. **AIChE Journal**, 46(5): 1007-1024, 2000.

MACHADO, M. C, **Projeto e implementação de filtro de kalman embarcado em FPGA para rastreamento de foguetes balístico.** CP ISSN 2178– 2229, 2014.

OLIVEIRA, J. R. P, **Acompanhamento de alvos-radar utilizando filtragem de kalman e vetores de estados com dimensão variável.** Dissertação de Mestrado/Universidade Federal do Rio de Janeiro, 2005.

PORFIRIO, C. R. **Implantação de um controlador multimodelos em uma coluna depropanizadora industrial.** Dissertação de Mestrado/Universidade de São Paulo, 2001.

QIN, S.J.; BADGWELL, T. A. An overview of industrial model predictive control technology. **Control Engineering Practice**, 11(7): 733-764, 2003.

SIMON, D.; **Optimal State Estimation: Kalman, H_{∞} , and Nonlinear Approaches.** Wiley-Interscience. 2006

SOTOMAYOR, O. A. Z.; **Modelagem, Identificação E Controle De Sistemas De Tratamento De Lodo Ativado Com Remoção De Nitrogênio.** PhD. Thesis, Escola Politécnica da Universidade de São Paulo, 2002.

SOTOMAYOR, O.A.Z. ODLOAK, Darci ; MORO, L.F.L; Closed-loop Model Re-identification of Processes under MPC with Zone Control. **Control Engineering Practice**,17(5):551-563, 2009.

YING, C.-M.; JOSEPH, B. Performance and stability analysis of LP-MPC and QP-MPC cascade control systems. **AIChE Journal**, 45(7): 1521-1534, 1999.

VINHAL, G. S, **Filtragem e melhoramento de espectros com filtro de kalman**,
Abakos ISSN 2316 – 9451, 2013.