



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**CONTROLE PREDITIVO BASEADO EM MODELO COM ESTIMAÇÃO DE
ESTADOS RESTRITA PARA CONTROLE E MONITORAMENTO DE PROCESSOS
NÃO LINEARES**

ROMERO FLORENTINO DE CARVALHO

ALEGRE, ES

2017

Romero Florentino de Carvalho

**CONTROLE PREDITIVO BASEADO EM MODELO COM ESTIMAÇÃO DE
ESTADOS RESTRITA PARA CONTROLE E MONITORAMENTO DE PROCESSOS
NÃO LINEARES**

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Química do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Engenharia Química.

Área de Concentração: Engenharia Química

Linha de Pesquisa: Modelagem, Otimização e Análise de Processos

Orientador: Prof. D.Sc. Julio Cesar Sampaio Dutra

Coorientador: Prof. D.Sc. Wellington Betencurte da Silva

ALEGRE, ES

Fevereiro de 2017

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial de Ciências Agrárias, Universidade Federal do Espírito Santo, ES, Brasil)

C331c Carvalho, Romero Florentino, 1992-
Controle preditivo baseado em modelo com estimação de estados restrita para controle e monitoramento de processos não lineares / Romero Florentino de Carvalho. – 2017.
140 f. : il.

Orientador: Julio Cesar Sampaio Dutra.

Coorientador: Wellington Betencurte da Silva.

Dissertação (Mestrado em Engenharia Química) – Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias.

1. Processo estocástico. 2. Estimação de estados. 3. Restrições operacionais. 4. Controle preditivo. 5. Filtro de partícula. I. Dutra, Júlio Cesar Sampaio. II. Silva, Wellington Betencurte da. III. Universidade Federal do Espírito Santo. Centro de Ciências Agrárias e Engenharias. IV. Título.

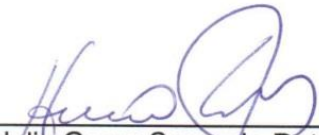
CDU: 66.0

**CONTROLE PREDITIVO BASEADO EM MODELO COM ESTIMAÇÃO DE
ESTADOS RESTRITA PARA CONTROLE E MONITORAMENTO DE PROCESSOS
NÃO LINEARES**


ROMERO FLORENTINO DE CARVALHO

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Química do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Engenharia Química.


Aprovado em 15 de fevereiro de 2017:



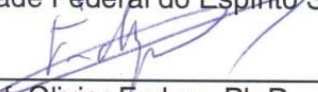
Prof. Julio Cesar Sampaio Dutra, D.Sc.
Universidade Federal do Espírito Santo



Prof. Wellington Betencurte da Silva, D.Sc.
Universidade Federal do Espírito Santo



Prof. Fabrício Thiengo Vieira, D.Sc.
Universidade Federal do Espírito Santo



Prof. Olivier Fudym, Ph.D.
Centre National de la Recherche Scientifique

DEDICATÓRIA

“Ao único que é digno de receber
A honra e a glória, a força e o poder
Ao Rei Eterno e imortal, invisível, mas real
A Ele ministramos o louvor”.
“Até aqui nos ajudou o SENHOR.” (1Sm.7:12c)

AGRADECIMENTOS

“Em tudo, dai graças, porque esta é a vontade de Deus em Cristo Jesus para convosco.” 1Ts. 5:18.

Todo motivo do meu Louvor e gratidão seja dado a Deus por intermédio de Jesus Cristo, pois por Ele temos vida, força, capacidade, dedicação, compromisso, persistência, paciência e amor para fazer tudo de todo coração, como para Ele e não para homens (Cl.3:23). A Deus o meu maior agradecimento, pela vida em Cristo, por seu grande amor, pelo seu perdão, pela fé, por suas mãos que curam, que trazem esperança, pela paz que excede todo entendimento humano e nos faz entender que esperar nEle é sempre caminhar. Ao SENHOR de toda glória a mais profunda expressão da minha gratidão.

É o SENHOR quem nos mantém com a sua misericórdia e com seu amor, Ele é quem nos rodeia de pessoas que também merecem nossa gratidão.

Aos meus queridos pais, Miguel e Neize, por sempre acreditarem no meu potencial, por dedicarem suas vidas para que momentos como esse fossem possíveis. Todas as minhas conquistas também são deles. À minha amada irmã Lorena, por também sempre me apoiar. A eles e aos demais da minha família, o meu muito obrigado.

A minha querida e doce Letícia, a minha gentil e meiga namorada, meu muito obrigado pelos incentivos nas horas difíceis, por acreditar sempre que esse dia iria chegar e pelas orações incessantes, por todo apoio, carinho e amor constantemente dedicados a minha pessoa.

Aos meus grandes amigos Victor, Samyr, Israel, Vinícius e Thiago pelo apoio de sempre, e ao amigo Marcos também pelo apoio nos conhecimentos computacionais.

Aos meus orientadores, Julio e Wellington, pelos ensinamentos a mim direcionados, pelas orientações, por depositar as suas confianças em mim e constantemente os seus incentivos.

Ao Olivier e o Fabrício pela atenção e por se disponibilizarem participar dessa banca.

A CAPES, pelo importante apoio financeiro.

RESUMO

CARVALHO, Romero. **Controle preditivo baseado em modelo com estimação de estados restrita para controle e monitoramento de processos não lineares**. 2017. Dissertação (Mestrado em Engenharia Química) – Universidade Federal do Espírito Santo, Alegre, ES. Orientador: Julio Cesar Sampaio Dutra. Coorientador: Wellington Betencurte da Silva.

O presente trabalho de mestrado discute sobre o problema de monitoramento e de controle preditivo com uma abordagem estocástica baseada em filtro de partículas com aplicação em problemas típicos da Engenharia Química, que em sua maioria, são não lineares e com incertezas não necessariamente gaussianas. O controle de processos químicos é de suma importância para que sejam garantidas as necessidades de qualidade, segurança e viabilidade econômica e operacional. No entanto, muitas das variáveis ligadas a esses objetivos não são medidas em linha ou apresentam incertezas significativas. Para isso, é necessário considerar ferramentas de estimação de estados para viabilizar o controle em linha. Neste sentido, a presente Dissertação investigou uma abordagem estocástica para o controle preditivo baseado em modelo (MPC), em que o esquema do MPC é combinado com filtro de partículas (PF), que é uma ferramenta de estimação sequencial do tipo Monte Carlo para sistemas não lineares e incertezas não gaussianas. Esta proposta considera também métodos de otimização para projeção das partículas que violam as restrições físicas ou operacionais, em uma região viável, chamado de CPF-MPC. Essa proposta estende resultados de trabalhos prévios ao incluir restrições nas variáveis de saída do processo. O CPF-MPC foi aplicado a dois estudos de caso: reator CSTR não isotérmico, com reação simples de primeira ordem e um CSTR com reação de van der Vusse. Por fim, o esquema PF – MPC foi aplicado em um circuito de moagem de minério de ferro e comparado com um controlador PI. Os resultados mostram que o CPF-MPC apresentou bons resultados e desempenho satisfatório para atender os objetivos de controle, garantindo um custo computacional relativamente baixo, redução de offset e perturbações nos parâmetros dos processos.

Palavras-chave: processos estocásticos, estimação de estados, restrições operacionais, controle preditivo, filtro de partículas.

ABSTRACT

CARVALHO, Romero. **Model Predictive Control with constrained state estimation for the control and monitoring of nonlinear process.** 2017. Dissertation. (Master degree in Chemical Engineering) – Federal University of Espírito Santo, Alegre, ES. Adviser: Julio Cesar Sampaio Dutra. Co-adviser: Wellington Betencurte da Silva.

The present master degree work discussed about monitoring and control problem with a stochastic approach based in particle filter with application in typical problems of Chemical Engineering, which mostly, are nonlinear and have uncertainty non necessarily Gaussian. The chemical process control is of paramount importance in order to guarantee the quality and safety needs, beyond economic and operational viability. However, many of the variables linked to these objectives are not online measurement or present significant uncertainties. For this, is necessary consider estimation tools for the enable online control. In this sense, the present dissertation investigated a stochastic approach for the model predictive control (MPC), in which the MPC scheme is combined with particle filter (PF), which is a Monte Carlo sequential estimation tools type for nonlinear systems and non-Gaussian uncertainties. This proposal also considers optimizations methods to the particles projection that violates the physical or operational constraints, in a viable region, originating the scheme with initials CPF-MPC. This proposal extends results from previous work by including constraints in the process output variables. This scheme was applied to two case studies: non-isothermal CSTR reactor with simple first order reaction and CSTR with van der Vusse kinetics. Finally, the PF-MPC scheme was applied in a run-of-mine ore milling circuit and compared to a PI control. The CPF-MPC results show a good and satisfactory performance to meet the control objectives, guaranteeing a relatively low computational time, reduction of the offset and process disturbance.

Keywords: Stochastic process, state estimation, operational constraints, predictive control, particle filter.

LISTA DE FIGURAS

Figura 1 - Evolução das publicações relacionadas aos temas Model Predictive Control e Bayesian State Estimation. Fonte: Science Direct (2017), modificado pelo autor.	21
Figura 2 - Exemplo ilustrativo das diferenças das Equações (35) - (38). Fonte: Shao, Huang e Lee (2010, p.148).....	36
Figura 3 - Exemplo ilustrativo da projeção da estimativa. Fonte: Zhao <i>et al.</i> (2012, p.683).	37
Figura 4 - Algoritmo de restrição proposto. Fonte: ZHAO et al., (2012), modificada pelo autor.	38
Figura 5 - Estrutura Básica do controlador MPC e seus principais elementos. Fonte: Muniz (2014, p. 46).	44
Figura 6 - Esquema de controle MPC, Fonte: Seborg, Edgar e Mellichamp (2003), modificada pelo autor.	45
Figura 7 - Esquema de evolução dos algoritmos MPC. Fonte: Qin e Badgwell, (2003), modificado pelo autor.....	46
Figura 8 - Esquema do ciclo de controle PF-MPC. Fonte: Stahl e Hauth (2011), modificado pelo autor.	57
Figura 9 - Esquema de controle UKF-MPC. Fonte: próprio autor.....	60
Figura 10 - Esquema de controle proposto CPF - MPC. Fonte: próprio autor.....	62
Figura 11 - Esquema do filtro para o algoritmo CUKF proposto. Fonte: próprio autor.	63
Figura 12 - Esquema do reator CSTR. Fonte: Stahl e Hauth (2011), modificada pelo autor.	69
Figura 13 - Esquema de resposta do comportamento das restrições na temperatura do reator de acordo com a perturbação realizada no <i>setpoint</i>	71
Figura 14 - Esquema do circuito de moagem. Fonte: Olivier, Haung e Craig (2012), modificado pelo autor.	76
Figura 15 - Esquema de controle com o controlador PF-MPC para o problema do circuito. Fonte: Próprio autor.	85
Figura 16 - Esquema de controle com o controlador PI para o controle do circuito. Fonte: Próprio autor.	86
Figura 17 - Comportamento da concentração para o esquema de controle (A) CPF-MPC e (B) PF-MPC, com restrições do tipo “túnel”.	96

Figura 18 - Comportamento da temperatura para o esquema de controle (A) CPF-MPC e (B) PF-MPC, com restrições do tipo “túnel”.....	98
Figura 19 - Comportamento da concentração para o esquema de controle (A) CPF-MPC e (B) UKF-MPC, com restrições do tipo “túnel”.....	100
Figura 20 - Comportamento da temperatura para o esquema de controle (A) CPF-MPC e (B) UKF-MPC, com restrições do tipo “túnel”.....	102
Figura 21 - Comportamento da concentração para o controlador (A) CPF-MPC e (B) CUKF-MPC, com restrições do tipo “túnel”.....	104
Figura 22 - Comportamento da temperatura para o esquema de controle (A) CPF-MPC e (B) CUKF-MPC, com restrições do tipo “túnel”.....	106
Figura 23 - Comportamento da Concentração do reagente A e B, e da temperatura do reator (C), quando não são consideradas perturbações no processo.....	108
Figura 24 – Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, quando não são consideradas perturbações no processo.....	109
Figura 25 - Comportamento da concentração de A e B, e da temperatura do reator (C), considerando um teste servo no <i>setpoint</i> da concentração de B.....	110
Figura 26 – Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, considerando um teste servo no <i>setpoint</i> da concentração de B.....	111
Figura 27 - Comportamento da concentração de A e B, e da temperatura do reator (C), considerando uma perturbação na concentração de alimentação do reagente A.....	112
Figura 28 – Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, considerando uma perturbação na concentração de alimentação.....	113
Figura 29 - Comportamento da concentração de A e B, e da temperatura do reator considerando um distúrbio na temperatura da alimentação.....	114
Figura 30 - Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, considerando um distúrbio na temperatura de alimentação.....	115
Figura 31 - Comportamento da variável controlada CARGA, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nas variáveis controladas PDE e VR.....	117

Figura 32 - Comportamento da variável controlada PDE, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nas variáveis controladas PDE e VR.	118
Figura 33 - Comportamento da variável controlada VR, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nas variáveis controladas PDE e VR.	119
Figura 34 - Comportamento da variável manipulada AM, para perturbações nas variáveis controladas PDE e VR.	121
Figura 35 - Comportamento da variável manipulada AAR, para perturbações nas variáveis controladas PDE e VR.	121
Figura 36 - Comportamento da variável manipulada AH, para perturbações nas variáveis controladas PDE e VR.	122
Figura 37 - Comportamento da variável controlada CARGA, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	125
Figura 38 - Comportamento da variável controlada PDE, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	126
Figura 39 - Comportamento da variável controlada VR, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	127
Figura 40 - Comportamento da variável manipulada AM, para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	129
Figura 41 - Comportamento da variável manipulada AAR, para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	129
Figura 42 - Comportamento da variável manipulada AH, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	130

LISTA DE TABELAS

Tabela 1 - Parâmetros, condições iniciais e propriedades físicas para o CSTR.	70
Tabela 2 - Condições para o teste, considerando restrições "túnel".	72
Tabela 3 - Propriedades físicas e parâmetros para o reator de Van der Vusse.	74
Tabela 4 - Condições iniciais para os estados e entradas.	74
Tabela 5 - Condições operacionais e restrições das variáveis do circuito.	77
Tabela 6 - Descrição dos subscritos do modelo.	78
Tabela 7 - Valores dos parâmetros para o modelo do circuito.	80
Tabela 8 - Condições operacionais do circuito.	84
Tabela 9 - Ruídos de medição da planta em percentual dos valores nominais das variáveis.	86
Tabela 10 - Variação dos parâmetros em relação ao seu valor nominal.	88
Tabela 11 - Conjunto de dados para as análises estatísticas para as simulações.	90
Tabela 12 - Análise estatística para o RMS, fixando o número de partículas.	91
Tabela 13 - Análise estatística para o AES, fixando o número de partículas.	92
Tabela 14 - Análise estatística para o RMS, fixando o desvio padrão do segundo filtro.	93
Tabela 15 - Análise estatística para o AES, fixando o desvio padrão do segundo filtro.	94
Tabela 16 - Critérios de desempenho CPF-MPC e PF-MPC.	97
Tabela 17 - Critérios de desempenho CPF-MPC e UKF-MPC.	101
Tabela 18 - Critérios de desempenho CPF-MPC e CUKF-MPC.	105
Tabela 19 - Planejamento de distúrbios para avaliação de desempenho do CPF-MPC.	107
Tabela 20 - Análise do RMS e AES para escolha da melhor estratégia de controle, em virtude das perturbações no <i>setpoint</i> de VR e PDE.	123
Tabela 21 - Análise do RMS e AES para escolha da melhor estratégia de controle, em virtude das perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r	131

LISTA DE SIGLAS

PI – Controlador Proporcional e Integral

PF-MPC – *Particle Filter – Model Predictive Control*

CPF-MPC – *Constrained Particle Filter – Model Predictive Control*

RMS – Root mean square error

AES – *Absolute Error Sum*

MATLAB – *Matrix Laboratory*

PF – *Particle Filter*

KF – *Kalman Filter*

EKF – *Extended Kalman Filter*

UKF – *Unscented Kalman Filter*

MHE – *Moving Horizon Estimation*

CSTR – *Continuous stirred tank reactor*

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Apresentação do tema de pesquisa	16
1.2	Motivação	20
1.3	Objetivos da Dissertação	22
1.4	Organização do texto	22
1.5	Trabalhos preliminares	23
2	O PROBLEMA DE ESTIMAÇÃO DE ESTADOS	25
2.1	Introdução à estimação de estados	25
2.2	Estimação Bayesiana sem restrição	26
2.2.1	Filtro de Kalman	27
2.2.2	Filtro de Kalman “Unscented”	29
2.2.3	Filtro de Partículas	31
2.3	Filtro de Partículas com restrição	33
2.3.1	Método de Aceitação/Rejeição	34
2.3.2	Método de Otimização	34
2.3.3	A Proposta do Filtro de Partículas com Restrição	37
2.4	Trabalhos da literatura com estimação via filtro de partículas com restrição	39
2.5	Comentários Finais	41
3	A TÉCNICA DE CONTROLE PREDITIVO	43
3.1	Introdução ao controle preditivo	43
3.2	Histórico do Controlador MPC	46
3.3	Formulação determinística do MPC	50
3.4	Comentários Finais	52
4	MPC ASSOCIADO A UM PROBLEMA DE ESTIMAÇÃO	53
4.1	MPC associado a Filtro de partículas	53
4.2	Filtro de Partículas – Controle Preditivo baseado em modelo (PF-MPC)	55
4.3	Filtro de Kalman <i>Unscented</i> – Controle Preditivo baseado em modelo (UKF-MPC)	59
4.4	Filtro de Partículas Restrito – Controle Preditivo baseado em modelo (CPF-MPC)	60
4.5	Filtro de Kalman <i>Unscented</i> Restrito – Controle Preditivo baseado em modelo (CUKF-MPC)	62
4.6	Comentários Finais	64
5	CONTROLE PREDITIVO COM FILTRO DE PARTÍCULAS RESTRITO E APLICAÇÃO EM ESTUDOS DE CASO	65
5.1	Controle Preditivo com estimação restrita	65
5.2	Estudo de Caso 1: Reator CSTR	68

5.3	Estudo de Caso 2: Reator de Van der Vusse.....	72
5.4	Estudo de Caso 3: Circuito de fragmentação e classificação do minério de ferro	76
5.4.1	Perturbação no setpoint: Teste servo	87
5.4.2	Perturbação nos parâmetros do processo: Teste regulador	87
6	RESULTADOS E DISCUSSÕES	89
6.1	Resultados: Estudo de caso 1.....	89
6.1.1	Avaliação dos parâmetros do CPF-MPC	89
6.1.1.1	Efeito do desvio padrão	90
6.1.1.2	Efeito do número de partículas	93
6.1.2	Comparação entre o CPF-MPC e o PF-MPC	95
6.1.3	Comparação entre o CPF-MPC e o UKF-MPC.....	99
6.1.4	Comparação entre o CPF-MPC e o CUKF-MPC.....	103
6.2	Resultados: Estudo de caso 2.....	107
6.2.1	Sem distúrbio no processo	108
6.2.2	Perturbação no setpoint da concentração do reagente B.....	109
6.2.3	Perturbação na concentração de alimentação do reagente A	111
6.2.4	Perturbação na temperatura de alimentação do reator	113
6.3	Resultados: Estudo de Caso 3.....	116
6.3.1	Perturbação nas variáveis controladas PDE e VR.....	116
6.3.2	Perturbação nos parâmetros	124
7	CONCLUSÕES E SUGESTÕES.....	132
8	REFERÊNCIAS	134

1 INTRODUÇÃO

Este capítulo destinou-se a realizar uma breve introdução referente ao problema proposto, constituído por uma apresentação do tema estudado, bem como a motivação da pesquisa e os objetivos que o presente trabalho pretendeu atingir, seguidos por uma descrição da estrutura de organização do texto.

1.1 Apresentação do tema de pesquisa

O controle de processos na indústria química consiste em um mecanismo essencial que objetiva atingir padrões relacionados a questões de segurança, meio ambiente, qualidade e lucratividade de uma planta. Contudo, no caso de plantas complexas, com muitas variáveis interagindo entre si, as estratégias de controle clássicas nem sempre são suficientes para atingir tais objetivos (SANTORO, 2011). A busca constante por desenvolvimento de novos processos e tecnologias, concomitante com a procura contínua do homem por inovação e aperfeiçoamento de técnicas e produtos, fazem com que seja necessário trabalhar em operações em regiões com características cada vez mais desafiadoras. Haja vista a necessidade de garantir esses padrões supracitados, o estudo acerca do controle de processos também necessita de uma evolução contínua (SILVA, 2014). Neste contexto, as técnicas pioneiras de MPC começaram a ser desenvolvidas no decorrer dos anos de 1970, impulsionadas pela crise do petróleo e a necessidade de ter em mãos um controle que solucionasse os problemas em refinarias (WANG, 2008).

É de costume, ao desenvolver uma estrutura de controle, dividir o problema proposto em camadas, que se baseiam nas distintas escalas de tempo em que os controladores podem atuar nas malhas (SKOGESTAD, 2000). No primeiro nível, ligado ao planejamento, calculam-se condições operacionais do processo que o orientam a uma produção com maior lucro possível e qualidade especificada. Essas condições são enviadas a uma camada de controle preditivo (camada supervisória), que busca calcular ações de controle ótimas em cada intervalo de tempo. Essas ações são enviadas como valores predeterminados (*setpoints*) para a camada regulatória, que tem como objetivo, manter a operação do processo com valores o

mais próximo possível das condições ótimas e garantir continuamente a estabilidade (SANTORO, 2011).

Os problemas reais tais como os problemas de biologia, química e física apresentam intrinsicamente em seu caráter não linearidades e perturbações de distribuição não gaussianas, tornando necessário um desenvolvimento de estratégias de controle que atendam com eficácia esses sistemas. A aplicação de controle não linear robusto garante ao processo uma maior estabilidade e melhor desempenho na presença de incertezas e perturbações. Este fato é conquistado pela introdução dos distúrbios diretamente ao modelo de predição do controlador, com o intuito de modelar o efeito das incertezas (STAHL; HAUTH, 2011; COETZEE; CRAIG; KERRIGAN, 2010).

Para uma ação de controle eficiente, é necessário que estejam disponíveis medições em tempo real adequadas do processo. Porém, mesmo alicerçado nos avanços tecnológicos dos últimos anos, o monitoramento dos processos ainda encontra desafios. Embora o estudo das técnicas utilizadas em monitoramento de variáveis de processos esteja em estado avançado, nem sempre é possível contar com dispositivos acessíveis para a determinação de variáveis e parâmetros importantes da operação, e quando eles existem, ocorrem problemas oriundos da precisão limitada dos mesmos e das instabilidades de leituras, provenientes de condições da planta, como vibrações e ruídos eletromagnéticos. Sendo assim, as informações oferecidas pelos sensores instalados na planta apresentam significativas incertezas, que na maioria das vezes afetam o desempenho do controle proposto, proporcionando aos processos condições de risco na segurança e qualidade da operação (DIAS *et al.*, 2016; NGUYEN *et al.*, 2015; DUTRA, 2012; HODOUIN, 2011).

Dessa forma, dado a importância do problema apresentado acima, técnicas de sensoriamento virtual têm se tornado uma alternativa atraente ao solucionar uma possível deficiência na medição das variáveis dos processos. Dentre essas técnicas, se encontram os Métodos Bayesianos, que possuem na literatura um quadro geral bastante interessante de sua aplicação como estimador de estado. Além disso, a estimação de estados possui bastante aplicabilidade em técnicas de controle avançado, nos quais o cálculo do sinal de controle ótimo depende dos valores dos estados (ZHAO *et al.*, 2012; QIN; BADGWELL, 2003; HENSON, 1998).

Os métodos Bayesianos constroem a distribuição de densidade posterior (PDF) do estado com base em todas as informações disponíveis em duas etapas: previsão e atualização, que são realizadas de forma iterativa (ZHAO *et al.*, 2012). Em geral, a solução analítica não está disponível, exceto em casos especiais, como por exemplo, o Filtro de Kalman (KF), sendo este uma solução analítica exata para sistemas dinâmicos gaussianos e lineares, o que de fato, limita a aplicação do mesmo. Quando se trata de processos não lineares e/ou com incertezas não gaussianas, outras técnicas foram desenvolvidas ao longo dos anos, como: o Filtro de Kalman Estendido (EKF), o Filtro de Kalman “*Unscented*” (UKF), a estimativa de horizonte móvel (MHE) e os métodos Sequenciais de Monte Carlo (SMC), também conhecidos como filtros de partículas (PF) (SHAO; HAUNG; LEE, 2010).

O EKF trabalha na linearização do modelo não linear do sistema em questão, sendo a solução mais usada nos últimos anos. Posteriormente o algoritmo original KF é utilizado na estimação. Entretanto, essa etapa de linearização do modelo limita a aplicação do EKF a processos que apresentam caráter não linear mais suave (JAZWINSKI, 1970). Essas limitações ocorrem devido a sua sensibilidade às condições iniciais e à sintonia das matrizes de covariância do ruído, podendo ocasionar instabilidade ou divergência na estimação (REIF *et al.*, 1999). O UKF, por sua vez, descarta a etapa de linearização, baseando-se em um procedimento numérico para a aproximação da média e da covariância dos estados, após realização de uma transformação não linear (chamada de “*Unscented transform*”) do sistema, dando ao método a possibilidade de solucionar problemas de processos fortemente não lineares (JULIER; UHLMANN, 2004). O MHE é capaz de tratar uma gama de sistemas não lineares, com restrições nos estados e sujeitos a distúrbios, de modo que o método é definido na literatura como vantajoso frente aos Filtros de Kalman (ZHAO; HAUNG; LIU, 2012). Contudo, em sua formulação, é preciso resolver um problema de programação não linear (NLP), possivelmente não convexo, com inúmeras equações de desigualdade e graus de liberdade, tornando o seu tempo de processamento maior que o tempo de amostragem, praticamente impossibilitando sua aplicação na execução de ações de controle sobre um sistema em tempo real, ao menos que sejam empregadas técnicas de otimização associadas ao algoritmo padrão MHE (TONEL, 2008).

O filtro de partículas tem ganhado bastante destaque devido a sua capacidade de lidar com sistemas não lineares com distribuição não gaussiana, além de não necessitar de simplificação, como linearização. O método consiste em resolver

numericamente o problema de estimação de estados recursivo de Bayes, fornecendo solução aproximada ao problema de inferência usando um número de partículas e seus respectivos pesos, aproximando assim a PDF do estado (SHAO; HUANG; LEE, 2010).

A maioria dos métodos Bayesianos existentes é incapaz de levar em conta as restrições e exige na maioria das vezes algumas simplificações. Todavia, provenientes de princípios físicos e limitações do processo, as restrições são comumente encontradas em problemas reais. Sendo assim, as restrições devem ser consideradas para assegurar eficiência da estimativa. A estimação de estados com restrições utilizando filtro de partículas tem sido estudada na literatura em duas propostas bem distintas, o método de aceitação/rejeição e o método de otimização. O primeiro trata apenas de limitações mais simples e simplesmente descarta as partículas fora dos limites operacionais. O segundo se baseia no princípio de minimizar uma função e possui deficiência, pois a otimização acarreta em um alto custo computacional (ZHAO; HUANG; LIU, 2012).

Diante do que foi exposto, a presente Dissertação consiste na utilização de uma abordagem estocástica em controle preditivo baseado em modelo (MPC) com aplicação dos filtros de partículas proposta por Stahl e Hauth (2011), denominada PF-MPC. Esta metodologia baseia-se no uso de dois filtros de partículas que trabalham em conjunto e interligados, no qual o primeiro filtro está dedicado a estimar os estados e o segundo filtro serve para determinar a entrada de controle ótima do processo a partir da predição das variáveis em um horizonte de tempo finito. Como contribuição, a fim de tratar das restrições sobre os estados de um sistema, diferente do algoritmo padrão PF-MPC, que apenas aborda as restrições nas variáveis manipuladas, esta Dissertação incorporou ao algoritmo de controle métodos de otimização com reamostragem para que a estimativa dos estados obedecesse aos limites operacionais dos sistemas.

A proposta deste trabalho é chamada aqui de CPF-MPC (do inglês, *Constrained Particle Filter – Model Predictive Control*), e foi avaliada considerando dois processos não lineares bastante estudados em Engenharia Química: o primeiro consiste em um reator de mistura perfeita (CSTR) com uma reação de primeira ordem; o segundo é o problema de referência (do inglês, *benchmark*) da cinética de Van der Vusse. Por fim, a estratégia PF-MPC, proposta por Stahl e Hauth (2011) foi aplicada em um circuito de fragmentação e classificação do minério de ferro.

Esta abordagem pode ser considerada inovadora, atual e de relevância, haja vista que nos últimos anos, tem crescido consideravelmente o número de pesquisas que relacionam a aplicação de filtros de partículas juntamente com controle preditivo.

1.2 Motivação

Em virtude das constantes mudanças sofridas pelo mundo, cada vez mais agudas ao longo do tempo, a busca por evolução na qualidade e funcionalidade dos produtos tem se tornado a razão da existência das empresas no contexto de processos modernos. Com a crescente concorrência e competitividade do mercado, a estagnação evolutiva dos produtos de uma empresa, pode gerar grandes perdas e prejuízos as indústrias. Segundo Dutra (2012) essas demandas geralmente são alcançadas por meio de recursos de integração, que por sua vez, podem gerar um comportamento dinâmico mais complexo ao sistema estudado.

Por ocasião desses fatores, estratégias de monitoramento, otimização e controle de processos transcendem a sua importância acadêmica e começam a possuir importância cada vez mais essencial no setor industrial. Essa necessidade, aliada ao notável crescimento de tecnologia computacional nos últimos anos, acarretaram em uma impulsão no desenvolvimento de projeto otimizado de produtos.

Nesse sentido, ao permitir o acompanhamento em tempo real das diversas variáveis imensuráveis, estados e parâmetros desconhecidos ou variantes dos processos químicos, a estimação tem se tornado uma técnica cada vez mais atrativa de monitoramento de processos industriais.

A literatura oferece diferentes métodos para estimação das variáveis dos processos: o KF fornece solução ótima para sistemas dinâmicos lineares, e técnicas como EKF, UKF, MHE e PF fornecem solução para os diversos sistemas não lineares encontrados em aplicações de Engenharia. A estimação de estados e parâmetros é parte integral de muitas estratégias de modelagem, monitoramento e controle de processos.

O crescente desenvolvimento de softwares eficientes de otimização conjuntamente aos notórios avanços no poder computacional no decorrer das últimas décadas, também permitiram progresso para a linha de pesquisa em controle ótimo para sistemas não lineares.

Inicialmente desenvolvidos para atender as necessidades específicas de refinarias de petróleo, os controladores MPC compõem uma classe com comprovada eficiência e aplicação industrial amplamente difundida, principalmente por apresentar desempenho satisfatório ao tratar de maneira eficiente de características peculiares presentes nesses processos, como existência de tempo morto, restrições nas variáveis manipuladas e controladas e por ter uma metodologia que garante fácil inclusão de objetivos econômicos diretamente no problema de controle ótimo (QIN; BADGWELL, 2003).

A Figura 1, elaborada por meio de dados retirados do *Science Direct*, apresenta a evolução no número de publicações relacionadas aos temas *Model Predictive Control* e *Bayesian State Estimation* ao longo dos últimos 20 anos. Nela, é possível observar a evolução do número de publicações relacionadas a controladores MPC, juntamente com aplicação de estimadores Bayesianos com restrição ao longo dos últimos anos. Devido à boa capacidade de estimação e facilidade de tratar com sistemas não lineares, além de relativo baixo esforço computacional exigido, o PF tem sido estudado por vários autores de forma associada ao controle MPC (ANDRIEU *et al.*, 2004; BLACKMORE, 2006; BOTCHU; UNGARALA, 2007; CHEN; MORRIS; MARTIN, 2005; CHEN; MORRIS; MARTIN, 2008; SCHAGEN *et al.*, 2008; KANTAS, MACIEJOWSKI; LECCHINI-VISINTINI, 2009, STAHL; HAUTH, 2011; LOPEZ, 2014; NISHIDA; SHIMADA, 2015; RASOULIAN; RICARDEZ-SANDOVAL, 2016).

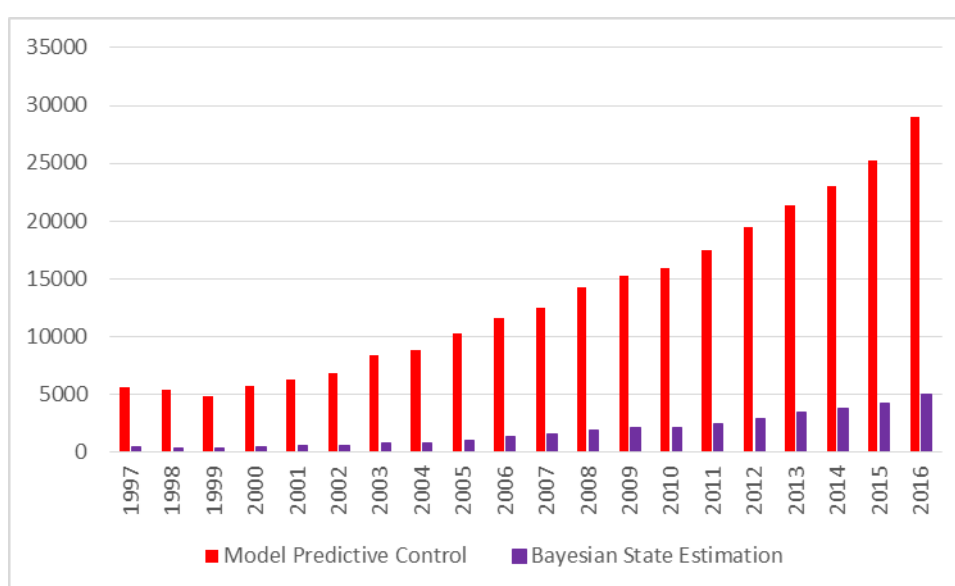


Figura 1 - Evolução das publicações relacionadas aos temas Model Predictive Control e Bayesian State Estimation. Fonte: Science Direct (2017), modificado pelo autor.

1.3 Objetivos da Dissertação

O principal propósito dessa Dissertação é a implementação e simulação computacional de um algoritmo de controle preditivo baseado em modelo (MPC) combinado com o filtro de partículas (PF), como ferramenta de estimação para sistemas não lineares e de incertezas não gaussianas. Associado a essa combinação, o presente trabalho também considera uma metodologia de restrição que se baseia em etapas de otimização e reamostragem para projeção das partículas que violam as restrições físicas ou operacionais destes a uma região viável. A este novo algoritmo deu-se o nome de *Constrained Particle Filter – Model Predictive Control* (CPF-MPC). Dentro desse escopo, visando avaliar o algoritmo proposto, os objetivos específicos deste trabalho são:

- (1) Implementar computacionalmente o algoritmo CPF-MPC, a partir do algoritmo padrão de controle preditivo baseado em modelo (MPC) com estimação via filtro de partículas (PF), denominado PF-MPC;
- (2) Comparar o desempenho do algoritmo proposto (CPF-MPC), com o PF-MPC e com algoritmos semelhantes, utilizando o estimador UKF, abordagem nomeada de CUKF-MPC e UKF-MPC, visando o monitoramento e controle em um reator CSTR com modelo não linear e reação de primeira ordem, no qual devem ser obedecidas restrições operacionais;
- (3) Testar e verificar a estabilidade e a resposta do algoritmo CPF-MPC para monitoramento e controle de um reator CSTR com modelo não linear e cinética de Van der Vusse em virtude de perturbações programadas no processo e restrições nos estados;
- (4) Avaliar o desempenho do algoritmo padrão PF-MPC ao controlar e monitorar um problema de grande dimensão e multivariável, comparando a sua performance com um esquema com controlador clássico PI para a variável de qualidade do produto.

1.4 Organização do texto

Um cenário de investigações teórico-computacionais foi explorado nesta Dissertação, cuja apresentação é estruturada nos seguintes capítulos:

No capítulo 2 são apresentados diferentes estimadores de estados, assim como a revisão de sua aplicação considerando as restrições em processos químicos.

O capítulo 3 traz os conceitos básicos e teóricos acerca de controle de processos químicos, tratando a abordagem convencional sobre controle preditivo baseado em modelos (MPC).

O capítulo 4 é dedicado à apresentação do algoritmo proposto por Stahl e Hauth (2011), PF-MPC, e também a formulação básica para implementação dos algoritmos CPF-MPC, UKF-MPC e CUKF-MPC propostos neste trabalho.

No capítulo 5 são apresentados os três estudos de caso. Juntamente com suas particularidades. É apresentada também a metodologia de verificação de desempenho dos esquemas de controle propostos para cada problema.

O capítulo 6 resume os resultados alcançados, discutindo as vantagens e limitações da metodologia proposta.

O capítulo 7 conclui o trabalho de Dissertação e aponta tendências para pesquisas futuras.

Por fim, o capítulo 8 apresenta as referências utilizadas.

1.5 Trabalhos preliminares

Esta Dissertação foi desenvolvida no Laboratório de Modelagem e Otimização de processos (MOP) do Programa de Pós-graduação em Engenharia Química (PPEQ) da UFES e está alinhada com os trabalhos em andamento no Grupo de Pesquisa em Métodos Computacionais, Controle e Estimação (LAMCES). Tal grupo se dedica a estudos referentes a controle de processos químicos aliado à aplicação de filtro de partículas para estimação de variáveis e parâmetros desses processos, além da utilização de métodos numéricos para resolução de problemas típicos da Engenharia Química, de acordo com os estudados no decorrer desta pesquisa, reatores químicos e operações unitárias na classificação e fragmentação de minério de ferro, gerando os trabalhos preliminares apresentados abaixo.

Um esquema de controle semelhante, ou seja, considerando além da ferramenta de controle, a ferramenta de estimação, foi avaliado para um reator CSTR em uma estrutura de controle cascata utilizando controladores PI. Os resultados obtidos

foram descritos no artigo intitulado “Filtro de partículas como observador online em um esquema de controle cascata para um reator contínuo” apresentado no XIX Encontro Nacional de Modelagem Computacional – XIX ENMC e VII Encontro de Ciência e Tecnologia de Materiais – VII ECTM, em João Pessoa (CARVALHO *et al.*, 2016). Este artigo se encontra apresentado no anexo da presente Dissertação. Por fim, o esquema de controle proposto, que utiliza o controle preditivo associado ao filtro de partículas com estimação restrita foi aplicado em dois estudos de caso: reator contínuo (CSTR) e o reator CSTR com cinética de Van der Vusse, culminando no artigo “*Constrained particle filter-model predictive control (CPF-MPC) for nonlinear process control and monitoring*” em fase de submissão para uma importante revista internacional.

2 O PROBLEMA DE ESTIMAÇÃO DE ESTADOS

Este capítulo traz um breve apanhado dos fundamentos teóricos básicos sobre estimadores Bayesianos existentes e suas aplicações, além de explorar o contexto de incorporação de estratégias de restrições nesses algoritmos. Este estudo é importante para a proposta da abordagem de controle preditivo associado à estimação com filtro de partículas. Desse modo, o presente capítulo busca introduzir os estimadores utilizados no decorrer desta Dissertação, apresentando a formulação matemática do problema de estimação Bayesiana e as formulações matemáticas dos filtros relevantes para o presente estudo.

2.1 Introdução à estimação de estados

Os valores dos estados de um sistema são de suma importância para as técnicas de controle avançadas como o MPC, nas quais esses valores são utilizados para determinar a ação ótima de controle. Com isso, os inúmeros processos químicos com aplicação em engenharia necessitam de um criterioso monitoramento do que ocorre no sistema (QIN; BADGWELL, 2003).

Para este fim, dispõe-se de sensores físicos que oferecem informação rápida acerca de variáveis do processo. Entretanto, em sistemas químicos reais geralmente essas variáveis não estão disponíveis para medição, principalmente em decorrência da falta de instrumentos capazes, pelo seu elevado preço ou pelo fato de poder haver falha na medição. Visto que os estados são elementos fundamentais em controle avançado, bem como no monitoramento de processos, detecção de falhas e otimização, torna-se necessário a observação desses valores. A literatura apresenta os estimadores de estados, que podem oferecer resultados satisfatórios a depender da natureza do sistema e dos níveis de incerteza das informações disponíveis (QIN; BADGWELL, 2003; OLIVIER, 2011; AGACHI, 2006).

Um estimador de estados é composto primordialmente por três partes: medidas do sistema (temperatura, concentração, vazão, entre outras), um modelo dinâmico que descreve o sistema e um algoritmo que arranja as informações obtidas anteriormente para atingir as estimativas (CUELLAR, 2013). Muitas vezes, o conhecimento prévio acerca do processo, através da modelagem, apresenta-o como

um modelo de transição de estado. Tal modelagem é composta do modelo de evolução de estados juntamente com o modelo de observação (DA SILVA, 2012).

Em virtude de suas incontáveis vantagens em reduzir incertezas, os métodos Bayesianos têm sido extensivamente estudados e utilizados com sucesso em várias áreas nos últimos anos (SHAO; HUANG; LEE, 2010; JULIER; UHLMANN, 2004; ZHAO; HUANG; LIU, 2012; NGUYEN *et al.*, 2015; KULIKOV; KULIKOVA, 2014).

Do ponto de vista bayesiano, o objetivo da estimativa é inferir a função de distribuição de probabilidade (PDF) do estado usando a informação a priori e a função de probabilidade, o que é alcançado por prever de forma iterativa os estados pelo modelo de transição e atualizar a estimativa, usando medidas em linha (QIN; BADGWELL, 2003; STAHL; HAUTH, 2011; SHAO; HUANG; LEE, 2010).

2.2 Estimação Bayesiana sem restrição

Inicialmente, pode-se considerar a representação geral de um sistema não linear descrito pelo modelo estocástico de tempo discreto dado pelas Equações (1) e (2).

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{y}_{k-1}, \mathbf{x}_k) + \boldsymbol{\omega}_k \quad (1)$$

$$\mathbf{y}_k = h_k(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{y}_{k-1}, \mathbf{x}_k) + \mathbf{v}_k \quad (2)$$

em que \mathbf{x}_k , \mathbf{y}_k , \mathbf{u}_{k-1} , $\boldsymbol{\omega}_k$ e \mathbf{v}_k são vetores que representam respectivamente, as variáveis estado, saída, entrada, o ruído do processo e o ruído de medição no tempo k . f_k e h_k são funções não lineares que descrevem o processo no tempo k (ZHAO *et al.*, 2012).

A partir de $\mathbf{Y}_k = [y_1, y_2, \dots, y_k]$, que indica a história de observações até o momento k , no contexto Bayesiano, a inferência de \mathbf{x}_k , dada uma realização das observações \mathbf{Y}_k depende da densidade *a posteriori* $p(\mathbf{x}_k | \mathbf{Y}_k)$, realizada por dois passos, como segue abaixo (ARULAMPALAM *et al.*, 2002; EBINGER *et al.*, 2015):

Passo de predição:

$$p(\mathbf{x}_k | \mathbf{Y}_{k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{Y}_{k-1}) d\mathbf{x}_{k-1} \quad (3)$$

Passo de atualização:

$$p(\mathbf{x}_k | \mathbf{Y}_k) = \frac{p(\mathbf{y}_k | \mathbf{x}_k)p(\mathbf{x}_k | \mathbf{Y}_{k-1})}{p(\mathbf{y}_k | \mathbf{Y}_{k-1})} \quad (4)$$

O principal objetivo da estimação Bayesiana é construir uma função densidade de probabilidade posteriori de um estado com base em todas as informações disponíveis (AFSHARI; GADSEN; HABIBI, 2017). As Equações (3) e (4) formam uma base para os esquemas de estimativa recursiva (ZHAO; HUANG; LIU, 2014).

Entretanto, a solução analítica da estimação recursiva somente é possível com a introdução de suposições adicionais. Um exemplo é o Filtro de Kalman, que supõe um problema com um modelo linear de transição de estados e medição e ruídos com distribuição de probabilidade Gaussiana de média zero (CUELLAR, 2013).

2.2.1 Filtro de Kalman

Os estimadores baseados na estrutura de Filtro de Kalman são amplamente difundidos devido a sua simplicidade e velocidade de cômputo. Para esses métodos, assume-se que todas as variáveis possuem distribuição gaussiana, que o sistema é linear e a informação estatística pode ser completamente descrita pela média e covariância. Desse modo, pode-se dizer que: aos estados e ruídos de medição são adicionados ruído gaussiano; as equações de transição de estados e de medição são conhecidas e lineares (AFSHARI; GADSEN; HABIBI, 2017).

O sistema linear é dado pelas Equações (5) e (6).

$$\mathbf{x}_k = \mathbf{A}_{k-1}\mathbf{x}_{k-1} + \mathbf{B}_{k-1}\mathbf{u}_{k-1} + \mathbf{w}_{k-1} \quad (5)$$

$$\mathbf{y}_k = \mathbf{C}_k\mathbf{x}_k + \mathbf{v}_k \quad (6)$$

Nesse modelo \mathbf{A}_{k-1} , \mathbf{B}_{k-1} são matrizes que descrevem as equações de transição de estados e \mathbf{C}_k é a matriz das medidas. Assumem-se ruídos gaussianos com média zero (ruído branco) para os estados e para as medições, respectivamente representados por \mathbf{w}_{k-1} e \mathbf{v}_k (OLIVIER, 2011).

O Filtro de Kalman (KF) consiste em duas etapas principais (previsão e correção). Na previsão, o filtro projeta uma estimativa no tempo atual utilizando a estimativa de estado do tempo anterior. A esta estimativa prevista, dá-se o nome de estimativa de

estado *a priori*. Na correção, o filtro usa medidas obtidas para corrigir a estimativa *a priori* e assim calcula a estimativa *a posteriori* melhorada (XAVIER, 2011).

O processo de estimação de um sistema representado pelas Equações (5) e (6), para o KF pode ser resumido da seguinte forma:

Passo 1: Predição: Calcula-se a estimativa *a priori* $\mathbf{x}_{k|k-1}$ e a covariância do erro *a priori* $\mathbf{P}_{k|k-1}$:

$$\mathbf{x}_{k|k-1} = \mathbf{A}_{k-1}\mathbf{x}_{k-1|k-1} + \mathbf{B}_{k-1}\mathbf{u}_{k-1} \quad (7)$$

$$\mathbf{P}_{k|k-1} = \mathbf{A}_{k-1}\mathbf{P}_{k-1|k-1}\mathbf{A}_{k-1}^T + \mathbf{Q}_{k-1} \quad (8)$$

Em que \mathbf{Q}_{k-1} é a matriz de covariância do ruído do processo.

Passo 2: Correção: Primeiramente, através do erro de medição $e_{y_{k|k-1}}$, e sua covariância \mathbf{S}_k , calcula-se o ganho de Kalman \mathbf{K}_k (uma matriz com objetivo de minimizar a covariância do erro *a posteriori*) (XAVIER, 2011).

$$\mathbf{e}_{y_{k|k-1}} = \mathbf{y}_k - \mathbf{y}_{k|k-1} \quad (9)$$

$$\mathbf{S}_k = \mathbf{C}_k\mathbf{P}_{k|k-1}\mathbf{C}_k^T + \mathbf{R}_k \quad (10)$$

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}\mathbf{C}_k^T\mathbf{S}_k^{-1} \quad (11)$$

Assim, a estimativa *a posteriori* $\mathbf{x}_{k|k}$ é dada pelo Filtro de Kalman, como combinação linear da estimativa *a priori* $\mathbf{x}_{k|k-1}$ e o erro de medição $e_{y_{k|k-1}}$. Por fim, calcula-se a covariância do erro *a posteriori* $\mathbf{P}_{k|k}$. \mathbf{R}_k significa a matriz de covariância do ruído de medidas (OLIVIER, 2011).

$$\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_k\mathbf{e}_{y_{k|k-1}} \quad (12)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k\mathbf{S}_k\mathbf{K}_k^T \quad (13)$$

Para um problema linear, com ruído gaussiano com média zero e desvio padrão conhecido para o processo e para as medidas, o Filtro de Kalman fornece uma solução ótima (SHAO; HUANG; LEE, 2010; TEIXEIRA; TÔRRES, 2010). Em se tratando de problemas de Engenharia é normal tentar formular modelos matemáticos lineares dos sistemas reais, ou ainda linearizar o sistema num determinado ponto de funcionamento. Isso se dá pela facilidade de manipular por ferramentas matemáticas esses modelos, assim como o fato de a teoria que suporta os sistemas lineares ser

mais completa e prática. Desse modo, para sistemas não lineares, outras técnicas, como versões do Filtro de Kalman e o Filtro de Partículas são utilizadas para fornecer a estimação dos estados.

2.2.2 Filtro de Kalman “Unscented”

O problema de estimação de estados em problemas não lineares e não gaussianos é muitas vezes de difícil solução, pois, a função de distribuição de probabilidade pode não ser completamente caracterizada pela média e a covariância. Desse modo, algumas aproximações considerando os filtros de Kalman garantem a estimação do estado. O método mais popular com base em linearização de modelo não linear de um sistema é o Filtro de Kalman Estendido (do inglês, *Extended Kalman Filter* EKF), no qual a linearização analítica ou numérica no Filtro de Kalman é empregada (SHAO; HUANG; LEE, 2010; TEIXEIRA, TÔRRES, 2010).

Contudo, essas aproximações para as funções de transição de estados e de medidas não são totalmente precisas, o que prejudica a confiabilidade na estimação em sistemas mais severamente não lineares (ABBEL *et al.*, 2005).

Em contrapartida, em lugar de linearizar o modelo não linear, o Filtro de Kalman *Unscented* (do inglês, *Unscented Kalman Filter* UKF) amostra de forma determinística um conjunto de pontos no espaço de estados do sistema dinâmico, chamadas de sigmas pontos. Após essa etapa, esses pontos são transformados, via *Unscented Transform* (UT), por meio de uma equação de evolução não linear e/ou uma equação de observação não linear (JULIER *et al.*, 2000).

Na formulação do algoritmo UKF, assume-se um vetor de estados $\mathbf{x}_{k|k}$ com dimensão (n), com média dada por $\bar{\mathbf{x}}_{k|k}$ e a covariância $\mathbf{P}_{k|k}$ aproximadas por $2n+1$ sigmas pontos, que são um conjunto de valores escolhidos deterministicamente (AFSHARI; GADSEN; HABIBI, 2017; TEIXEIRA; TÔRRES, 2010).

O processo de estimação do UKF também pode ser representado pelas etapas de previsão e correção:

Passo 1: Previsão: Primeiramente, calcula-se os sigmas pontos, como descrito pelas Equações (14) - (16):

$$\boldsymbol{\chi}_{k|k}^0 = \bar{\mathbf{x}}_{k|k}, \quad i = 0 \quad (14)$$

$$\boldsymbol{\chi}_{k|k}^i = \bar{\mathbf{x}}_{k|k} + \left(\gamma \sqrt{\mathbf{P}_{k|k}} \right)_i, \quad i = 1, \dots, n \quad (15)$$

$$\boldsymbol{\chi}_{k|k}^{i+n} = \bar{\mathbf{x}}_{k|k} - \left(\gamma \sqrt{\mathbf{P}_{k|k}} \right)_i, \quad i = 1, \dots, n \quad (16)$$

Em que o parâmetro $\gamma = \sqrt{n + \kappa}$ é o peso associado das amostras, que é determinado conforme as Equações (17) e (18):

$$\mathbf{w}_0 = \kappa / (n + \kappa), \quad i = 0 \quad (17)$$

$$\mathbf{w}_i = 1/2(n + \kappa), \quad i = 1, \dots, 2n \quad (18)$$

Nessas Equações, κ é um fator de escala, $\left(\sqrt{n + \kappa} \mathbf{P}_{k|k-1} \right)_i$ representa uma coluna ou uma linha qualquer da matriz quadrada de $n + \kappa \mathbf{P}_{k|k-1}$ e \mathbf{w} são pesos, que possuem soma normalizada igual a um (AFSHARI; GADSEN; HABIBI, 2017).

É possível então, calcular a média da previsão do estado, bem como a previsão da covariância *a priori*, dadas pelas Equações (19) - (21):

$$\boldsymbol{\chi}_{k|k-1}^i = f\left(\boldsymbol{\chi}_{k|k}^i\right) \quad (19)$$

$$\bar{\mathbf{x}}_{k|k} = \sum_{i=0}^{2n} \mathbf{w}_i \boldsymbol{\chi}_{k|k-1}^i \quad (20)$$

$$\mathbf{P}_{k|k-1} = \mathbf{Q}_k + \sum_{i=0}^{2n} \mathbf{w}_i \left[\boldsymbol{\chi}_{k|k}^i - \bar{\mathbf{x}}_{k|k-1} \right] \left[\boldsymbol{\chi}_{k|k}^i - \bar{\mathbf{x}}_{k|k-1} \right]^T \quad (21)$$

De acordo com Xavier (2011), sempre que há disponível uma nova medição, o filtro entra em uma etapa de correção. Contudo, antes disso, deve-se calcular a previsão da medida $\mathbf{y}_{k|k-1}$ através das Equações (22) e (23):

$$\boldsymbol{\zeta}_{k|k-1}^i = h\left(\boldsymbol{\chi}_{k|k-1}^i\right) \quad (22)$$

$$\mathbf{y}_{k|k-1} = \sum_{i=0}^{2n} \mathbf{w}_i \boldsymbol{\zeta}_{k|k-1}^i \quad (23)$$

Passo 2: Correção: Nesta etapa, calcula-se a covariância do erro da medida $\mathbf{P}_{\mathbf{y},k|k-1}$, bem como a covariância da relação entre a medida e o estado, conforme as Equações (24) - (25):

$$\mathbf{P}_{y,k|k-1} = \sum_{i=0}^{2n} \mathbf{w}_i \left[\xi_{k|k-1}^i - \mathbf{y}_{k|k-1} \right] \left[\xi_{k|k-1}^i - \mathbf{y}_{k|k-1} \right]^T \quad (24)$$

$$\mathbf{P}_{xy,k|k-1} = \sum_{i=0}^{2n} \mathbf{w}_i \left[\chi_{k|k-1}^i - \mathbf{x}_{k|k-1} \right] \left[\xi_{k|k-1}^i - \mathbf{y}_{k|k-1} \right]^T \quad (25)$$

Calcula-se então o ganho de Kalman \mathbf{K}_k , a estimativa *a posteriori* do estado $\mathbf{x}_{k|k}$ e a covariância do estado *a posteriori* $\mathbf{P}_{k|k}$.

$$\mathbf{K}_k = \mathbf{P}_{xy,k|k-1} \mathbf{P}_{y,k|k-1}^{-1} \quad (26)$$

$$\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \mathbf{y}_{k|k-1}) \quad (27)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{P}_{y,k|k-1} \mathbf{K}_k^T \quad (28)$$

Apesar de sua aplicabilidade levar a uma estimação dos estados mais precisa, o UKF assume que, mesmo após a transformação UT, as variáveis do sistema são gaussianas. Além disso, em um cenário com restrições, esse filtro pode não apresentar um desempenho satisfatório (SHAO; HUANG; LEE, 2010).

2.2.3 Filtro de Partículas

Diferentemente dos métodos de estimativa Bayesianos tradicionais, o Filtro de Partículas (PF) não impõe suposições sobre a função de densidade de probabilidade (PDF) e nas relações entre as variáveis, ou seja, os sistemas podem ser de fato não lineares e não gaussianos. Baseado em Simulação de Monte Carlo, a função de densidade de probabilidade *a posteriori* $p(\mathbf{x}_k | \mathbf{Y}_k)$, ser aproximada por um conjunto de partículas aleatórias \mathbf{x}_k^i e seus respectivos pesos w_k^i de forma discreta, representada por um somatório (ZHAO; HUANG; LIU, 2013), conforme descrito pela Equação (29).

$$p(\mathbf{x}_k | \mathbf{Y}_k) = \frac{1}{N} \sum_{i=1}^N w_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (29)$$

Nessa equação δ é a função delta de Dirac e N é o número de partículas. De forma ideal, as partículas seriam amostradas a partir da verdadeira *a posteriori* $p(\mathbf{x}_k | \mathbf{Y}_k)$. Como a mesma não é disponível, outra distribuição, denominada

distribuição de importância ou distribuição proposta $q(\mathbf{x}_k | \mathbf{X}_{k-1}, \mathbf{Y}_k)$ substitui $p(\mathbf{x}_k | \mathbf{Y}_k)$ visando melhorar a eficiência da amostragem por importância, de modo que o peso w_k^i correspondente para cada partícula é representado pela Equação (30) (ARULAPALAM *et al.*, 2002; LÓPEZ-NEGRETE; PARTWARDHAN; BIEGLER, 2011):

$$\mathbf{w}_k^i = \frac{p(\mathbf{x}_k | \mathbf{Y}_k)}{q(\mathbf{x}_k | \mathbf{X}_{k-1}, \mathbf{Y}_k)} \quad (30)$$

A seleção da distribuição proposta se baseia no princípio de que $q(\mathbf{x}_k | \mathbf{X}_{k-1}, \mathbf{Y}_k)$ deve conter $p(\mathbf{x}_k | \mathbf{Y}_k)$. Desse modo, a escolha mais popular para a distribuição proposta é a função probabilística da equação de estado, ou seja, $q(\mathbf{x}_k | \mathbf{X}_{k-1}, \mathbf{Y}_k) = p(\mathbf{x}_k | \mathbf{x}_{k-1})$ (ZHAO *et al.*, 2012).

A importância dos pesos é derivada como:

$$\mathbf{w}_k^i \propto p(\mathbf{y}_k | \mathbf{x}_{k-1}) \quad (31)$$

Na estimação Bayesiana, as partículas tendem a ser degeneradas. Isso significa, que há um aumento gradativo da variância dos pesos, ou seja, pode ocorrer o caso extremo em que após as iterações, apenas uma partícula possui peso não desprezível. A solução típica do filtro de partículas para este problema é a utilização do procedimento de reamostragem. Esta etapa possibilita ao algoritmo do filtro a reprodução de partículas em áreas com maior probabilidade (DOUCET; GODSILL; ANDRIEU, 2000). Dessa forma, é possível determinar as partículas a posteriori (mais importantes) e então calcular a estimativa média dos estados:

$$\mathbf{x}_k = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_k^i \quad (32)$$

De acordo com Kyriakides, Morrel, Papandreou-Sppappola (2005) o algoritmo genérico do filtro de partículas, sem levar em conta a restrição, pode ser resumido pelos seguintes passos:

Passo 1 – Inicialização: Geração das partículas iniciais $\{\mathbf{x}_0^i\}_{i=1}^N$ a partir da distribuição *a priori* $p(\mathbf{x}_0)$, e fazer $k = 1$;

Passo 2 – Amostragem por importância: Geração das partículas *a priori* $\{x_k^{i-}\}_{i=1}^N$ a partir da distribuição de amostragem por importância $p(x_k^{i-} | x_{k-1}^{i-})$;

Passo 3 – Cálculo dos pesos: Calcular os pesos de cada partícula a cada medição disponível no tempo k e normalizar os pesos de acordo com $\bar{w}_k^i = w_k^i / \sum_{i=1}^N w_k^i$;

Passo 4 – Reamostragem: Geração das partículas *a posteriori* $\{x_k^i\}_{i=1}^N$, com base nas informações de ponderação e estratégia de reamostragem, e recalculando os pesos, da seguinte forma: $\bar{w}_k^i = 1/N$;

Passo 5 – Saída do filtro: Estimar os estados de acordo com $\hat{x}_k = 1/N \sum_{i=1}^N x_k^i$ e fazer $k+1$. Voltar ao passo 2.

2.3 Filtro de Partículas com restrição

Provenientes de alguns aspectos físicos e operacionais, por exemplo, frações molares não negativas ou offset restrito em uma faixa, os estados dos processos químicos apresentam comumente algumas limitações em seus valores. Essas restrições aparecem normalmente sob a forma de relações algébricas de igualdade ou desigualdade, ou simplesmente como limites inferiores e superiores. Portanto, para garantir a validade da estimação, é necessário considerar essas restrições no método de estimação utilizado (SHAO; HUANG; LEE, 2010; ZHAO, HUANG; LIU, 2014).

O algoritmo padrão para o PF não considera restrições e, como resultado, algumas partículas podem violar as faixas viáveis do processo. Esta seção introduz os métodos existentes para lidar com limitações no contexto de filtro de partículas e, em seguida, é apresentada a metodologia aplicada por (ZHAO et al., 2012).

2.3.1 Método de Aceitação/Rejeição

O método aceitação/rejeição, conhecido como clipping, trabalha com a aplicação das restrições sobre as partículas a priori, ou seja, antes da etapa de reamostragem. As partículas dentro dos limites são aproveitadas, ao passo que, as partículas presentes em regiões que se encontram fora dos limites são descartadas. Usando esse conceito, os pesos das partículas anteriores são calculados pela Equação (33) (ZHAO, HUANG, LIU, 2012; KYRIAKIDES, MORREL, PAPANDREOU-SPPAPPOLA, 2005).

$$w_k^i \begin{cases} 0, & se(x_k^{i-} \in \mathbb{R}^n) \\ \propto p(\mathbf{y}_k | \mathbf{x}_k^{i-}) & se(x_k^{i-} \notin \mathbb{R}^n) \end{cases} \quad (33)$$

As partículas que se encontram fora da região viável são rejeitadas e paralelamente o mesmo número de novas partículas é produzido, satisfazendo as restrições do sistema em estudo. Finalmente, as novas partículas geradas, juntamente com as partículas que anteriormente já se encontravam dentro do limite requerido, são usadas para gerar as partículas a posteriori (ZHAO; HUAN; LIU, 2014).

As principais vantagens referentes a este método é o fato dele garantir que todas as partículas estejam dentro do limite de restrição, além de não precisar de uma alta demanda computacional (SHAO; HUANG; LEE, 2010). Entretanto, dentre suas desvantagens estão o fato de as partículas “ruins” serem descartadas, o que pode acarretar em um empobrecimento da amostra. Outros contrapontos estão relacionados ao fato do método não ser suficientemente bom para lidar com restrições mais complicadas, além da possibilidade de nenhuma das partículas se encontrarem dentro do limite exigido (ZHAO *et al.*, 2012).

2.3.2 Método de Otimização

Um método que se baseia em princípios de otimização apresenta-se como eficaz alternativa para tratar de restrições mais complexas, faixa em que o método por aceitação/rejeição não consegue atuar. Partindo do princípio de uma estimativa a posteriori máxima, o estado pode ser estimado da seguinte forma (ZHAO; HUANG; LIU, 2012):

$$\begin{aligned} \mathbf{x}_k &= \arg \max p(\mathbf{x}_k | \mathbf{Y}_k) \propto \arg \max p(\mathbf{x}_k | \mathbf{Y}_{k-1}) p(\mathbf{y}_k | \mathbf{x}_k) \\ &\propto \arg \max p_{v_k}(\mathbf{y}_k - h_k(\mathbf{x}_k^{i-})) p_{x_k^e}(\mathbf{x}_k - \mathbf{x}_k^{i-}) \end{aligned} \quad (34)$$

Nesta equação, a função p_{v_k} corresponde à distribuição do ruído das medidas (v_k). Sabe-se que $p(\mathbf{x}_k | \mathbf{Y}_{k-1})$ é desconhecida. De tal forma se assume que $\mathbf{x}_k = \mathbf{x}_k^{i-} + \mathbf{x}_k^e$ é a estimativa otimizada de \mathbf{x}_k por meio de $p(\mathbf{x}_k | \mathbf{Y}_{k-1})$. A função $p_{x_k^e}$ é a distribuição de probabilidade de \mathbf{x}_k^e aproximada por uma função exponencial ou uma dupla exponencial. Tendo em vista essas colocações, as restrições podem ser impostas sobre as partículas *a priori*, *a posteriori* e sobre a estimativa do estado, expressadas pelas Equações (35) - (38) (SHAO; HUANG; LEE, 2010):

$$\min_{\substack{i- \\ \mathbf{x}_k}} -\log\left(p_{x_k^e}\left(\mathbf{x}_k^{i-} - \mathbf{x}_k^{i-}\right)\right) \quad (35)$$

$$\min_{\substack{i- \\ \mathbf{x}_k}} -\log\left(p_{x_k^e}\left(\mathbf{x}_k^{i-} - \mathbf{x}_k^{i-}\right)\right) - \log\left(p_{v_k}\left(\mathbf{y}_k - h_k\left(\mathbf{x}_k^{i-}\right)\right)\right) \quad (36)$$

$$\min_{\substack{i \\ \mathbf{x}_k}} -\log\left(p_{x_k^e}\left(\mathbf{x}_k^i - \mathbf{x}_k^i\right)\right) - \log\left(p_{v_k}\left(\mathbf{y}_k - h_k\left(\mathbf{x}_k^i\right)\right)\right) \quad (37)$$

$$\min_{\substack{x \\ \mathbf{x}_k}} -\log\left(p_{x_k^e}\left(\mathbf{x}_k - \mathbf{x}_k\right)\right) - \log\left(p_{v_k}\left(\mathbf{y}_k - h_k\left(\mathbf{x}_k\right)\right)\right) \quad (38)$$

Nessas Equações, o “~” acima das variáveis indica o valor da variável projetada pelo método de otimização, \mathbf{x}_k^e determina o erro de estimação sujeito à distribuição $p_{x_k^e}$ (ZHAO *et al.*, 2012).

Baseado nas equações acima, o método de otimização busca encontrar um valor ótimo dentro da região de restrição, substituindo aquelas partículas que violaram algum limite. Assim, a Equação (35) apresenta a formulação utilizada para tratar das partículas *a priori* e leva em consideração apenas o desvio entre os valores das partículas projetadas e daquelas que violaram a restrição, trazendo a partícula fora desse limite ao valor da fronteira transgredida; a Equação (36) faz uma troca da diferença entre as partículas projetadas e as que violaram as restrições pelo desvio entre o valor medido e o valor otimizado, de forma que as partículas *a priori* são atraídas para dentro da região viável; a Equação (37) trabalha de modo similar ao proposto pela (36) impondo restrições às partículas *a posteriori*; a Equação (38) também apresenta a mesma formulação algébrica, porém, tratando do problema de restrição na estimativa do estado (ZHAO; HUANG; LIU, 2014).

A Figura 2 esquematiza o procedimento das Equações (35) - (38). Na Figura 2 a estrela representa o valor exato do estado; os círculos não preenchidos as partículas dentro do limite de restrição; os círculos pretos as partículas que violaram a restrição; o losango a estimativa do estado; o retângulo o espaço em que as partículas são geradas e a elipse a região de restrição do estado estimado (ZHAO; HUANG; LIU, 2012).




Figura 2 - Exemplo ilustrativo das diferenças das Equações (35) - (38). Fonte: Shao, Huang e Lee (2010, p.148).

Os métodos apresentados pelas Equações (35) - (37) asseguram que tanto as partículas *a priori* quanto as partículas *a posteriori* são geradas dentro de uma região de restrição, o que resulta em uma estimativa dos estados que também respeita esta região desejada. Entretanto, essa otimização aplicada às partículas (*a priori* ou *a posteriori*) pode diminuir a variedade das partículas, tornar a estimativa conservadora, além de aumentar muito o custo computacional dependendo do número de partículas (ZHAO; HUANG; LIU, 2014).

As partículas *a priori* são geradas através das partículas *a posteriori* no tempo $k-1$. A estimativa é definida pela média das partículas *a posteriori*, o que torna essas partículas elementos essenciais no processo de estimação de estados. Contudo, a Figura 3 mostra que quando a estimativa viola a restrição e a otimização é realizada diretamente na estimativa de estados, a geração das partículas *a posteriori* torna-se comprometida. Primeiramente, calcula-se a média otimizada, pela Equação (38),

projetada na região de restrição dos limites do sistema, e a covariância da amostra é calculada como se segue (ZHAO *et al.*, 2012):

$$\mathbf{P}_k = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{x}_k^i - \mathbf{x}_k) (\mathbf{x}_k^i - \mathbf{x}_k)^T \quad (39)$$




Figura 3 - Exemplo ilustrativo da projeção da estimativa. Fonte: Zhao *et al.* (2012, p.683).

Em seguida, as partículas *a posteriori* são geradas de forma aleatória levando em conta uma distribuição gaussiana com covariância \mathbf{P}_k e média \mathbf{x}_k , e todos os cálculos são realizados baseados na hipótese que eles satisfazem a distribuição Gaussiana. Todavia, um mérito do filtro de partículas está na sua capacidade em lidar com função de distribuição de probabilidade não Gaussiana. Desse modo, essa otimização limita a PDF como distribuição Gaussiana e pode acarretar em um fraco desempenho para o sistema (ZHAO *et al.*, 2012; ZHAO; HUANG; LIU, 2014).

2.3.3 A Proposta do Filtro de Partículas com Restrição

De acordo com a proposta de Zhao *et al.* (2012), ao ser detectada a violação da estimativa do estado, as Equações (37) e (38) são utilizadas para torna-la válida. A Equação (38) é usada para calcular uma estimativa ótima de \mathbf{x}_k . Contudo, como discutido acima, ocasiona a geração de partículas *a posteriori* pobres. A Equação (37) é aplicada para obter partículas *a posteriori* válidas e, assim, conseguir uma estimativa dentro da faixa de restrição. Isso demanda elevado tempo computacional, já que todas as partículas que violaram a restrição devem ser projetadas para a região viável.

Visando melhorar o desempenho da estimativa e uma menor carga computacional, algumas partículas *a posteriori* que violam a restrição são escolhidas de forma aleatória e projetadas à região válida, até que a estimativa esteja também dentro dessa região. Dessa forma, a estimativa válida é obtida sem que todas as partículas

a posteriori necessitem passar por etapas de otimização. O método pode ser apresentado no fluxograma da Figura 4 (ZHAO *et al.*, 2012):

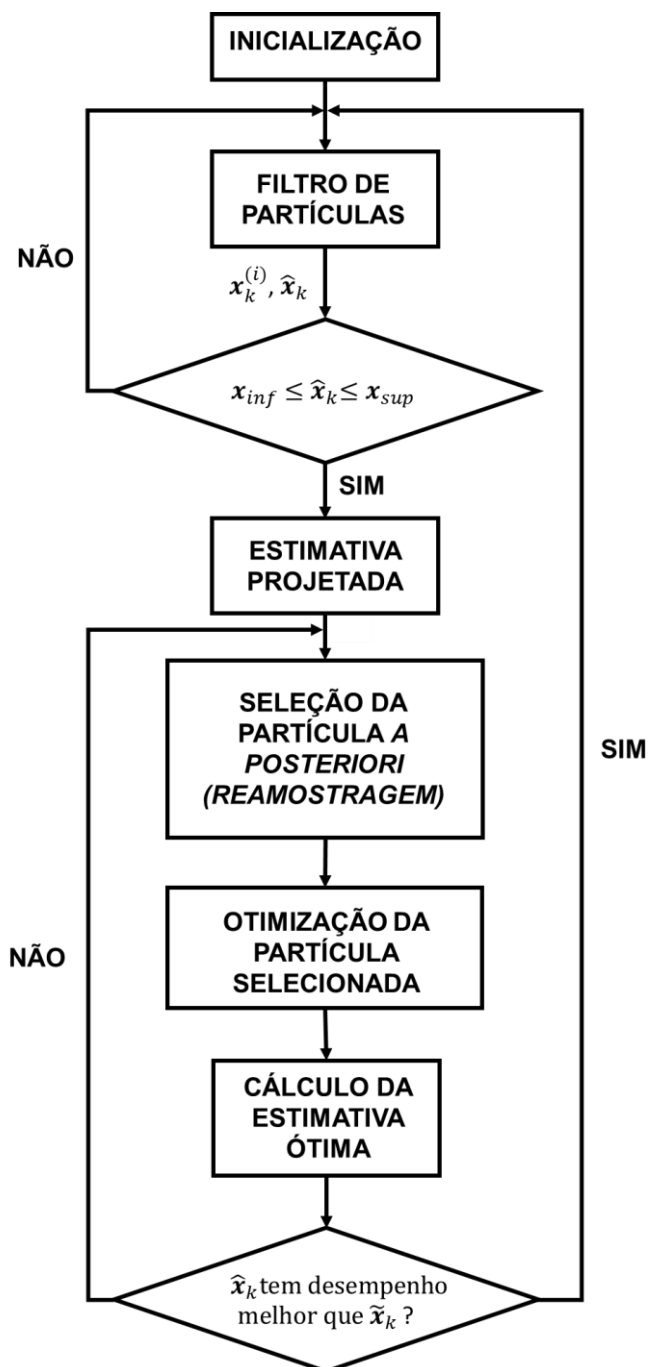


Figura 4 - Algoritmo de restrição proposto. Fonte: ZHAO *et al.*, (2012), modificada pelo autor.

O fluxograma pode ser detalhado de acordo com as etapas listadas abaixo:

Passo 1 – Verificação de violação: Após o cálculo da média das partículas *a posteriori*, é verificada se a estimativa violou a restrição. Em caso de violação, utiliza-

se a Equação (38), calculando uma estimativa projetada \mathbf{x}_k dentro da região de restrição, caso contrário, faz-se $k+1$;

Passo 2 – Reamostragem: As partículas *a posteriori* que violam a restrição (1 a m) são escolhidas aleatoriamente após serem geradas com uma distribuição uniforme. Logo após, a partícula *a posteriori* \mathbf{x}_k^i escolhida de forma aleatória é projetada para a região válida;

Passo 3 – Otimização: A Equação (37) é então usada para calcular a projeção da partícula selecionada;

Passo 4 – Cálculo da estimativa: Calcula-se a média \mathbf{x}_k das partículas juntamente com a nova partícula projetada. O passo 3 e 4 são iterativos, até que \mathbf{x}_k tenha desempenho melhor que \mathbf{x}_k , ou todas as partículas forem projetadas, e faz-se $k+1$. Zhao *et al.* (2012) define que o melhor desempenho é relacionado à distância da estimativa dentro da região de restrição com relação ao limite definido, ou seja, desempenho melhor para o valor mais distante das fronteiras da região de restrição.

2.4 Trabalhos da literatura com estimação via filtro de partículas com restrição

Historicamente, o algoritmo apresentado em aplicações de estimação via filtro de partículas não possui elementos relacionados à incorporação de restrições impostas pelos sistemas. Atualmente, novas abordagens possuem destaques na literatura ao utilizarem conceitos de estimação por SMC ao lidar com limites operacionais dos processos, compartilhando de uma mesma ideia básica, porém apresentando determinadas características que os tornam distintos.

Shao, Huang e Lee (2010) apresentaram em seu trabalho um novo algoritmo de PF considerando restrições. O novo método foi baseado nas estratégias de aceitação/rejeição e otimização, no qual os autores utilizaram de uma abordagem híbrida que mescla vantagens de ambas as técnicas. Os autores compararam o algoritmo apresentado, com o próprio PF sem restrição, com o UKF, EKF e o MHE sem restrição, além de compará-lo também com o UKF e o MHE com esquema de restrição de otimização e o EKF com o esquema *clipping*. Os autores concluíram através dos resultados obtidos que o método proposto foi eficaz ao tratar as restrições e possui robustez em relação a informações *a priori* ruins.

Zhao, Huang e Liu (2012) avaliaram diversos métodos de amostragem e propuseram uma metodologia de amostragem com restrição a fim de integrar as limitações dos processos no algoritmo PF. Essa investigação foi realizada através de imposição de restrições sobre as partículas *a priori*, *a posteriori* e sobre a estimativa do estado. A fim de garantir que não houvesse violação dos limites nas partículas *a priori* foi utilizado um método de restrição chamado transformada inversa de amostragem. No que diz respeito às partículas *a posteriori*, a solução foi realizar uma formulação que seleciona as partículas *a priori* válidas, e realizar a reamostragem baseando-se apenas nessas partículas válidas, garantindo a geração de partículas *a posteriori* dentro da região de restrição. Por fim, ao avaliar a estimativa do estado, foi aplicado um método em que as partículas *a posteriori* boas fossem reproduzidas e as partículas *a posteriori* ruins, descartadas. Ao comparar com métodos existentes, o método proposto implementou as restrições, sem nenhum procedimento de otimização e nenhuma suposição restritiva sobre as distribuições, demonstrando sua efetividade ao tratar com este problema.

O trabalho de Zhao *et al.* (2012) abordou a investigação da restrição diretamente na estimação, no lugar de imposição sobre as partículas. Segundo o mesmo trabalho, se a estimativa viola a restrição, uma estimativa ótima é obtida primeiramente por uma etapa de otimização e, posteriormente, uma estratégia conjunta de reamostragem e otimização é utilizada para amostrar aleatoriamente uma partícula *a posteriori* fora da região de restrição, uma por vez, projetando-as para dentro da região viável. Essa etapa conjugada entre otimização e reamostragem é iterada até que o estado estimado atinja um desempenho melhor do que a estimativa otimizada anteriormente. Os autores compararam essa técnica com outras da literatura em estimação que utilizam otimização e concluíram que o método possui melhor relação carga computacional versus obtenção de partículas *a posteriori* eficazes.

Zhao, Huang e Liu (2013) formularam um algoritmo de estimação que incorporou restrições nos estados, no qual as informações no instante de tempo anterior foram diretamente utilizadas para o alcance da estimativa atual, de forma que o estado estimado no período de tempo anterior é dado como uma “medida” do processo. O método foi avaliado através de uma simulação em um processo de fermentação da penicilina. Para a etapa de estimação de estados, os resultados demonstraram a eficácia do método em tratar com as restrições.

Zhao, Huang e Liu (2014) propuseram uma abordagem de PF com restrições para a estimativa dos estados. Neste novo método, três estratégias alternativas foram

avaliadas para impor restrições sobre as partículas *a priori*, sobre as partículas *a posteriori* e sobre o estado estimado. Para os dois primeiros casos (partículas *a priori* e *a posteriori*), utilizou-se a metodologia de Zhao, Huang e Liu (2012). Em terceiro lugar, para a estimativa que violou a restrição, foi proposto um método que utiliza a abordagem de projeção juntamente com a de aceitação/rejeição. Tal método propôs um equilíbrio entre a distribuição *a priori* e a função de verossimilhança, ajustando os pesos das partículas que violam e as partículas que se encontram dentro da região de restrição, respectivamente. Foi confirmada sua eficácia em tratar restrições e, em comparação com outros métodos, a abordagem proposta neste trabalho fornece uma melhor interpretação física e não envolve suposições restritivas sobre as distribuições.

Ebinger *et al.* (2015) avaliaram uma formulação restrita ao PF. Os autores mostraram que os métodos comuns de estimação PF com restrição restringem a densidade posterior do estado, em vez da estimativa média, levando a considerações mais severas e possivelmente que se encontra em regiões diferentes ou até mesmo irrelevantes do que as restrições originais. Dessa forma, os autores propuseram uma alternativa para a estimação via filtro de partículas com restrições, impondo as restrições sobre a estimativa média, sem restringir ainda mais a densidade posterior do estado, comparando com os métodos de projeção usuais, em um modelo severamente não linear. Dessa forma, os autores concluíram que sua proposta, além de obter uma estimativa mais precisa do estado, com menor erro médio quadrático e variância, preservava também as propriedades de convergência do PF para a densidade posterior de estado ótima.

2.5 Comentários Finais

Neste capítulo foi apresentado um apanhado teórico referente aos métodos de estimação utilizados no decorrer desta Dissertação para o monitoramento das variáveis dos processos em estudo. Além disso, também foi levantado um histórico sobre as propostas de algoritmos que tratavam o problema estimação de estados com restrições, útil no desenvolvimento de estratégias de controladores MPC para processos não lineares.

Desse modo, visando a aplicação do esquema proposto, o próximo capítulo detalha a teoria de controle preditivo para a regulação dos sistemas em estudo.

3 A TÉCNICA DE CONTROLE PREDITIVO

Este capítulo visa a apresentação de uma fundamentação para a etapa projeto de controle de processos com o algoritmo de controle preditivo (MPC), seguida de alguns comentários finais.

3.1 Introdução ao controle preditivo

Em sistemas de controle com arranjo *feedback*, como os controladores clássicos do tipo PID, o sinal de saída do controlador é determinado a partir do valor da variável que se deseja controlar. Para um controlador preditivo baseado em modelo (abordagem bem conhecida como MPC – *Model Predictive Control*), o sinal de entrada não é derivado apenas do estado atual da planta. O MPC faz uso também de um modelo de processo que descreve a dinâmica do sistema visando à predição do comportamento futuro em um dado horizonte de predição (DURAISKI, 2001).

Apoiado nesta predição, em cada instante de tempo o algoritmo preditivo busca otimizar o desempenho da planta por meio de uma sequência futura das entradas de controle, que são determinadas a partir da minimização de uma função objetivo. Posteriormente, a primeira entrada da sequência ótima de controle é aplicada ao processo. Por fim, repetem-se todas as etapas do algoritmo, porém deslocadas de um passo no tempo (QIN; BADGWELL, 2003; STAHL; HAUTH, 2011; RAWLINGS; MAYNE, 2012).

O MPC possui uma longa história no campo da engenharia de controle. Por exemplo, no decorrer dos anos 1970, com o advento da crise do petróleo, houve uma busca por soluções para o controle de refinarias. Isso fez do controle preditivo uma das poucas áreas que recebeu concomitantemente interesse de pesquisadores das comunidades, tanto na academia quanto na indústria (WANG, 2008).

A forma mais básica e difundida desse tipo de é o controle preditivo baseado em modelo e, quando comparado com outras técnicas de controle, apresenta uma série de vantagens, dentre elas (SEBORG; EDGAR; MELLICHAMP, 2003; CAMACHO; BORDONS, 2004; WANG, 2008):

- Ser uma técnica atrativa aos operadores, com conceitos intuitivos e sintonia simples;

- Possuir abrangência em uma grande gama de processos (simples, complexos, tempo morto e sistemas instáveis);
- Possibilitar o tratamento de restrições de todos os tipos;
- Compensar intrinsecamente o tempo morto com seu caráter preditivo;
- Permitir a otimização de processos em linha (*online*).

A Figura 5 apresenta a estrutura básica do MPC, juntamente com o detalhamento de cada um dos seus elementos principais.

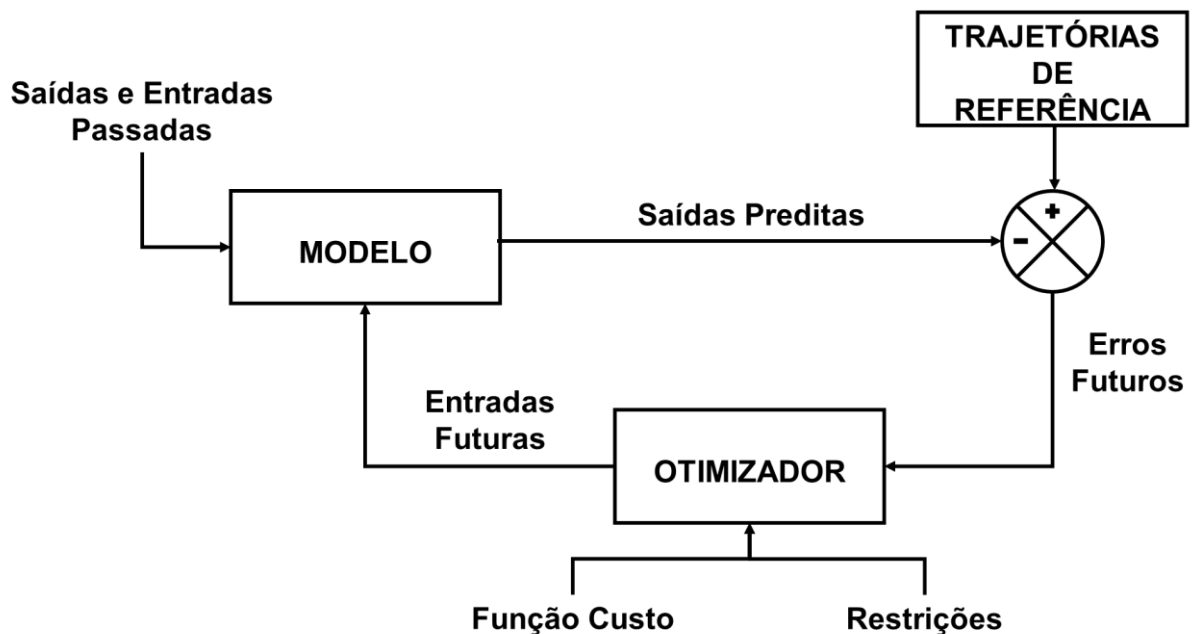


Figura 5 - Estrutura Básica do controlador MPC e seus principais elementos. Fonte: Muniz (2014, p. 46).

Dos Santos (2007) apresentou a definição básica de cada um desses elementos da seguinte maneira:

- Trajetória de referências – Denota o comportamento que se deseja obter para a saída futura da planta. Seu conhecimento prévio oferece ao controlador uma característica antecipativa (também conhecida como *feedforward*);
- Modelo – Procura-se a representação mais precisa do comportamento dinâmico através de um modelo matemático que, dependendo da ocasião, pode ser linear ou não linear, ou ainda, atualizado por meio de métodos de identificação *online*, fornecendo ao controlador uma característica adaptativa;
- Otimizador – Tem como incumbência minimizar uma função objetivo a cada tempo de amostragem, obtendo uma ação de controle ótima, garantindo o desempenho adequado do processo. A função que se deseja minimizar pode

abranger parcelas associadas ao erro futuro, ao acréscimo do sinal de controle, além de outros termos que forneçam ao controlador propriedades que melhorem o seu desempenho em virtude das particularidades do processo.

A Figura 6 apresenta um esquema referente ao conceito básico da estratégia MPC. No tempo k atual, o comportamento da variável controlada é predito ao longo de um horizonte de predição N_p tomando como condição inicial os dados medidos. As ações de controle $u(k)$ no horizonte de controle N_c são calculadas objetivando a minimização do erro entre o que foi predito $y(k+1,2,\dots,N_p)$ e a trajetória de referência, também conhecida como valor desejado ou *setpoint* do processo (SEBORG; EDGARD; MELLICHAMP, 2003).




Figura 6 - Esquema de controle MPC, Fonte: Seborg, Edgar e Mellichamp (2003), modificada pelo autor.

De acordo com Silva (2014), ao realizar o cálculo das ações de controle, somente a primeira é aplicada na planta e as demais são descartadas, ou ainda, utilizadas como estimativas iniciais no otimizador. No instante de tempo subsequente, todo procedimento é repetido baseado nas novas informações de medidas disponíveis. Esse princípio é conhecido como "Princípio do Horizonte Móvel" (*Receding Horizon*).

Essa seção também visa à apresentação de uma breve revisão histórica do MPC, descrevendo as ideias básicas de cada algoritmo proposto. Originalmente criada visando à solução de problemas específicos de controle em refinarias de petróleo, a tecnologia MPC pode ser encontrada atualmente em uma ampla variedade de áreas, incluindo produtos químicos, processamento de alimentos, área automotiva e espacial (WANG, 2008).

3.2 Histórico do Controlador MPC

Esta seção compreende em uma curta revisão histórica do desenvolvimento do controlador MPC, cujo esquema da evolução temporal e gerações podem ser vistos na Figura 7.

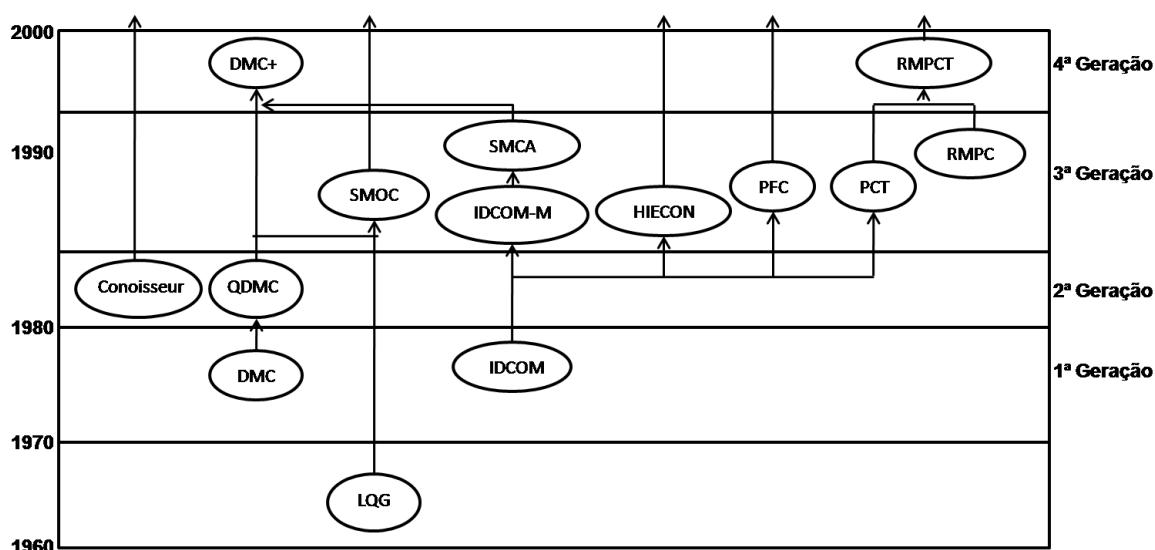


Figura 7 - Esquema de evolução dos algoritmos MPC. Fonte: Qin e Badgwell, (2003), modificado pelo autor.

A evolução dos conceitos de controle moderno pode ser buscada no trabalho do grupo de Kalman, datado no início dos anos 60. O procedimento é explicado utilizando os estados de acordo com as Equações (40) e (41) (MUNIZ, 2014).

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}\mathbf{u}_k + \mathbf{G}\mathbf{w}_k \quad (40)$$

$$\mathbf{y}_k = \mathbf{C}\mathbf{x}_k + \xi_k \quad (41)$$

O vetor \mathbf{u}_k representa as entradas ou variáveis manipuladas do processo, o vetor \mathbf{y}_k descreve a saída do processo, enquanto o vetor \mathbf{x}_k retrata os estados. A perturbação de estado é \mathbf{w}_k e o ruído de medição é ξ_k , ambos são gaussianos e apresentam média igual a zero. O estado inicial \mathbf{x}_0 é considerado como gaussiano, porém com média diferente de zero.

A função objetivo a ser minimizada pode ser vista na Equação (42). A mesma atua penalizando erros da variável controlada em relação a uma trajetória especificada, conjuntamente, a mudanças da variável manipulada. A função objetivo apresentada é quadrática na forma da equação, podendo também assumir alguma variação da mesma (MUNIZ, 2014). Os termos da norma são definidos na Equação (43).

$$J = \sum_{j=1}^{\infty} \|\mathbf{x}_{k+j}\|_Q^2 + \|\mathbf{u}_{k+j}\|_R^2 \quad (42)$$

$$\|\mathbf{x}\|_Q^2 = \mathbf{x}^T \mathbf{Q} \mathbf{x} \quad (43)$$

De acordo com Qin e Badgwell (2003), nesta formulação está implícita a suposição de que todas as variáveis são escritas em termos de desvios em relação a um estado desejado. A solução do problema conhecido como controlador LQG (*Linear Quadratic Gaussian*) envolve duas etapas. No instante de tempo k , a medida \mathbf{y}_k é utilizada para obter uma estimativa ótima dos estados $\mathbf{x}_{k|k}$, conforme descrito nas Equações (44) e (45).

$$\mathbf{x}_{k|k-1} = \mathbf{A} \mathbf{x}_{k-1|k-1} + \mathbf{B} \mathbf{u}_{k-1|k-1} \quad (44)$$

$$\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \mathbf{C} \mathbf{x}_{k|k-1}) \quad (45)$$

Sendo assim, a entrada ótima \mathbf{u}_k é calculada utilizando um controlador de estado proporcional ótimo, conforme mostra a Equação (46):

$$\mathbf{u}_k = -\mathbf{K}_C \mathbf{x}_{k|k} \quad (46)$$

Nessas Equações, \mathbf{K}_k significa o ganho do filtro de Kalman e \mathbf{K}_C o ganho do controlador. Essas matrizes são calculadas a partir da solução da equação da matriz de Ricatti. Esse algoritmo faz uso de um horizonte de predição infinito, proporcionando ao mesmo poderosas propriedades de estabilização. Para um modelo linear, o método mostrou-se estável para qualquer planta de aplicação. Contudo, restrições sobre o processo nas entradas, estados e saídas não foram

consideradas no desenvolvimento da teoria LQG. Os problemas e limitações do algoritmo listadas abaixo impactaram no menor desenvolvimento da tecnologia em indústrias (MUNIZ, 2014; QIN; BADGWELL, 2003):

- Restrições;
- Processos não lineares;
- Incertezas do modelo (robustez);
- Critério de desempenho único;
- Razões culturais.

Sabe-se que um controlador para obter sucesso em sua aplicação necessita de promover a manutenção do sistema em um ponto mais próximo possível das exigências operacionais, de forma que as restrições não sejam violadas. Além disso, as unidades de processo são em geral complexas, não lineares, com restrições multivariáveis e cuja dinâmica varia com o tempo, devido a mudanças nas condições operacionais, ação de catalisadores, entre outros. Outro problema está relacionado à formulação do modelo usado, que por muitas vezes é difícil de ser expresso em estrutura LQG. Todavia, o pretexto mais importante que fez com que a teoria LQG não tivesse forte impacto está relacionado à visão da comunidade de controle, que quase sempre não possui contato expressivo com os conceitos LQG ou o considera impraticável (QIN; BADGWELL, 2003).

Todo esse panorama, diga-se de passagem, problemático, acarretou em uma busca por meios de controle que abrangem modelos mais gerais, resolvendo de forma *online* o problema de otimização dinâmica a cada passo da etapa de controle. Foi nesse contexto que a tecnologia atual MPC, citada no início desta seção, foi desenvolvida, ou seja, uma metodologia mais flexível, com novas técnicas de identificação, permitindo estimativas mais rápidas e reduzindo o custo de desenvolvimento do modelo (MUNIZ, 2014).

Os primeiros relatos descritos que envolviam aplicações de controle preditivo datam do ano de 1976. Tais trabalhos foram apresentados pelo grupo de pesquisa de Richalet no referido ano e, posteriormente, resumido pelos próprios autores em 1978. Ao projeto desenvolvido foi atribuído o nome de MPHC (*Model Predictive Heuristic Control*) e o *software* de solução foi denominado IDCOM, sigla que define identificação e comando. Segundo Faccini (2011), o trabalho de Richalet já apresenta características peculiares do controle preditivo que destacam o potencial da técnica, tais como: facilidade em lidar com problemas MIMO (*Multiple Input*

Multiple Output), utilização de um modelo interno que prediz relações entre as entradas e saídas e a determinação de uma trajetória de referência a ser alcançada. Engenheiros da Shell, buscando o desenvolvimento da sua própria abordagem MPC, desenvolveram sua própria tecnologia MPC, no início da década de 1970, com uma aplicação inicial apresentada em 1973. O algoritmo desenvolvido, denominado DMC (*Dynamic Matrix Control*), apresentou uma metodologia que utiliza um modelo linear de resposta ao degrau que relaciona alterações na saída do processo com um somatório e pondera os valores anteriores das modificações na estrutura (CUTLER; RAMAKER, 1979; *apud* QIN; BADGWELL, 2003, p.738). Para o caso SISO (*Single Input Single Output*) o modelo do processo é do tipo:

$$\mathbf{y}_{k+j} = \sum_{i=1}^{N-1} \mathbf{s}_i \Delta \mathbf{u}_{k+j-i} + \mathbf{s}_N \mathbf{u}_{k+j-N} \quad (47)$$

\mathbf{s}_j são os pesos móveis e representam os coeficientes da resposta ao degrau. Utilizando um modelo da resposta ao degrau, é possível escrever variações preditas para as saídas como uma combinação linear das variações das entradas futuras. A matriz que realiza essa conexão é chamada de Matriz Dinâmica. Essa metodologia permite o cálculo do vetor ótimo analiticamente tal qual a solução de um problema de mínimos quadrados. Em termos práticos, a matriz inversa utilizada é calculada *off-line*, reduzindo o tempo computacional (MUNIZ, 2014).

Os algoritmos IDCOM e DMC fazem parte da primeira geração da tecnologia MPC e possuíram grande apelo industrial, servindo como marco para o paradigma do MPC nas indústrias.

É de conhecimento da academia que os processos possuem restrições e particularidades que fazem com que os algoritmos IDCOM e DMC não sejam tão excelentes. Tais fatos fizeram com que fosse adicionado ao algoritmo DMC uma programação quadrática, colocando restrições sobre as variáveis de saída e entrada, gerando o algoritmo QDMC (*Quadratic Program Dynamic Matrix Control*) (GARCÍA; MORSHEDI, 1986). As principais características do algoritmo QDMC incluem:

- Modelo linear de resposta ao degrau para a planta;
- Objetivo de desempenho quadrático em um horizonte de predição finito;
- Especificação do comportamento futuro da saída, com o objetivo de seguir o *setpoint*;

- Entradas ótimas calculadas pela solução de uma programação quadrática.

Conforme o controle preditivo foi ganhando notoriedade, era preciso uma abrangência que cobria problemas mais complexos. O algoritmo QDMC forneceu uma estratégia para incorporar restrições, contudo não havia uma forma clara para tratar com soluções impossíveis. Segundo Prett e García (1988), a incorporação de objetivos múltiplos na função objetivo impossibilita que sejam avaliados critérios relevantes sobre o desempenho de um controlador.

O IDCOM-M (*Identification and Command Multiple*), o HIECON (*Hierarchical Constraint Control*), o SMCA (*Setpoint Multivariable Control Architecture*) e SMOC 46 (*Shell Multivariable Optimizing Controller*) fazem parte da chamada terceira geração de controladores MPC, onde diversas restrições são avaliadas, mecanismos de recuperação de soluções impossíveis são fornecidos e processos dinâmicos de caráter antagônicos são tratados (MUNIZ, 2014).

Com o mercado cada vez mais interessado e o grande apelo às técnicas MPC, surgiram mudanças significativas no cenário industrial para o controle preditivo. Algumas metodologias se juntaram visando atender a enorme demanda, exemplo disso são o DMC-plus e o RMPCT. Ambos fazem parte da quarta geração de tecnologia da MPC e possuem as seguintes características: janelas com interface gráfica para o usuário; níveis de otimização múltiplas abordando a prioridade de controle; inclusão de objetivos econômicos; consideração de incertezas nos modelos; melhorias de identificação dos modelos (QIN; BADGWELL, 2003).

3.3 Formulação determinística do MPC

Embora a maioria das aplicações em Engenharia Química seja de caráter estocástico, devido a alguns problemas com medições complexas, flutuações em dados dos processos, entre outros, esta seção trata da formulação determinística do MPC clássico. No domínio de tempo discreto ($k = 0, 1, 2, \dots$), o sistema de controle pode ser definido pelas equações diferenciais e restrições dadas pelas Equações (48) - (51) (RAWLINGS; MAYNE, 2012; LOPEZ, 2014).

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k) \quad (48)$$

$$\mathbf{y}_k = g(\mathbf{x}_k) \quad (49)$$

$$\mathbf{x}_k \in \mathcal{X} \subset \mathbb{R}^n \quad (50)$$

$$\mathbf{u}_k \in \mathbf{U} \subset \mathbb{R}^m \quad (51)$$

Nessas Equações, \mathbf{x}_k representa o estado, \mathbf{u}_k a entrada e \mathbf{y}_k a saída. Geralmente as restrições são limitadas como apresentadas nas Equações (52) e (53), sendo \mathbf{x}_{\min} , \mathbf{x}_{\max} , \mathbf{u}_{\min} e \mathbf{u}_{\max} valores constantes.

$$\mathcal{X} = \left\{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{x}_{\min} \leq \mathbf{x} \leq \mathbf{x}_{\max} \right\} \quad (52)$$

$$\mathbf{U} = \left\{ \mathbf{u} \in \mathbb{R}^m \mid \mathbf{u}_{\min} \leq \mathbf{u} \leq \mathbf{u}_{\max} \right\} \quad (53)$$

A estratégia MPC consiste em solucionar um problema de controle ótimo em malha aberta para cada intervalo de tempo k em determinado horizonte de previsão N_p . Fixando-se o tempo em k , o referido problema pode ser pensado como um problema de otimização em relação a uma determinada função $J(\mathbf{x}_k, \bar{\mathbf{u}}_{k:(k+N_p)}, N_p)$, na qual define-se $\bar{\mathbf{u}}_{k:(k+N_p)} := \{\bar{\mathbf{u}}_k, \dots, \bar{\mathbf{u}}_{k+N_p}\}$. Para entender melhor tal afirmação, a barra sobre as variáveis indicam que as mesmas são previstas no tempo k , distinguindo as mesmas da variável u_k (STAHL; HAUTH, 2011).

O problema de controle ótimo, em termos de função objetivo, em geral é indicado por uma função quadrática, sujeita ao modelo e às restrições, sob a forma da Equação (54). Nesta Equação, \mathbf{s}_j define a trajetória das saídas do sistema que por obrigação precisam ser preferencialmente atingidas pelo controle do sistema (LOPEZ, 2014).

$$J = \sum_{j=k}^{k+N_p} \left\| \bar{\mathbf{u}}_j - \bar{\mathbf{u}}_{j-1} \right\|_{\mathbf{Q}}^2 + \left\| \mathbf{s}_j - \mathbf{x}_{j-1} \right\|_{\mathbf{R}}^2 \quad (54)$$

A Equação (55) representa a sequência de entradas ótimas, na qual o primeiro valor \mathbf{u}_k^* dessa sequência é utilizado como entrada de controle no instante k . No instante $k+1$, em que nova saída \mathbf{y}_k é disponibilizada, o procedimento de otimização se repete (STAHL; HAUTH, 2011).

$$\mathbf{u}_{k:(k+N_p)}^* = \arg \min_{\mathbf{u}_{k:(k+N_p)}} J(\mathbf{x}_k, \bar{\mathbf{u}}_{k:(k+N_p)}, N_p) \quad (55)$$

A minimização da função objetivo resulta em um problema clássico de otimização, sujeito às restrições na saída do sistema, na variável manipulada, bem como no nível de alteração da variável manipulada (IKOKEN, 2013). Conforme as Equações , a variação representa uma sequência de movimentos de controle futuros no horizonte de controle.

$$\mathbf{y}_{\min} < \mathbf{y} < \mathbf{y}_{\max} \quad (56)$$

$$\mathbf{u}_{\min} < \mathbf{u} < \mathbf{u}_{\max} \quad (57)$$

$$\Delta \mathbf{u}_{\min} < \Delta \mathbf{u} < \Delta \mathbf{u}_{\max} \quad (58)$$

Em geral, um sistema real e determinístico como dado pelas Equações (48) e (49) pode ser aumentado por componentes estocásticos, como ruídos na distribuição dos estados e nas variáveis de medidas. Nestes casos, devido às não linearidades e perturbações não gaussianas, a abordagem determinística do controlador MPC pode falhar, e técnicas de estimação podem ser usadas para proporcionar solução aproximada à estimação que acontece nesses modelos (STAHL; HAUTH, 2011).

3.4 Comentários Finais

Como exposto no presente capítulo, o controlador MPC tem ganhado bastante espaço em aplicações reais de todas as classes. A formulação apresentada visa a tratar de um sistema representado por equações discretas no domínio do tempo de forma determinística. Contudo, na maioria das aplicações reais, os modelos dos processos possuem em geral, algum tipo de elemento de caráter estocástico, devido alguns problemas com medições complexas e também flutuações em dados dos processos.

Desse modo, é preciso que seja apresentado para sistemas dinâmicos não lineares, a formulação de resolução de problemas de otimização. O capítulo a seguir é destinado a essa apresentação.

4 MPC ASSOCIADO A UM PROBLEMA DE ESTIMAÇÃO

Os métodos Bayesianos supracitados são frequentemente utilizados como estimadores. Porém, nos últimos anos tem-se expandido suas aplicações e os mesmos estão sendo explorados como ferramentas numéricas para aproximação de problemas de otimização. Por ocasião da forma sequencial com que os sistemas dinâmicos se apresentam, aliados a simplicidade dos algoritmos SMC, essas técnicas se tornaram mais apropriadas para resolução de problemas de otimização estocástica (STAHL; HAUTH, 2011).

4.1 MPC associado a Filtro de partículas

Atualmente, novas abordagens possuem destaques na literatura ao utilizarem conceitos de estimação por SMC na formulação do problema de controle ótimo do controlador MPC, compartilhando de uma mesma ideia básica, porém apresentando características que os tornam distintos.

Inicialmente, Andrieu *et al.* (2004) apresentaram uma abordagem em que o filtro de partículas é utilizado em controle com a finalidade de fornecer a estimativa pontual em um determinado instante. Desse modo, foi calculada a estimativa, por meio de uma média pontual utilizando uma nuvem de partículas. Essa estimativa foi então empregada no cálculo da ação de controle em um problema clássico de otimização do controlador MPC.

Blackmore (2006) apresentou um método para um controle estocástico de horizonte finito em sistemas dinâmicos sujeitos a restrições, o qual não fez o uso do algoritmo do filtro de partículas para a geração das partículas, mas aproximou o problema estocástico original como um determinista usando um grande número de partículas. Ao controlar as trajetórias de cada uma das partículas, pode-se gerar soluções ótimas e determinar a que deve ser implementada.

Botchu e Ungarala (2007) dividiram o problema em duas partes: a primeira consiste em um estimador de estado que trabalha para calcular estimativas atuais dos estados medidos e não medidos do processo, enquanto que a segunda etapa é formada por um controlador MPC que calcula a entrada de controle ótima que visa a conduzir os respectivos estados para seus valores determinados (*setpoints*).

Em Engenharia Química, a utilização de uma abordagem que mistura filtro de partículas com controle preditivo pode ser vista em alguns trabalhos. Por exemplo, Chen, Morris e Martin (2005) aplicaram um filtro de partículas em contraste com um filtro de Kalman estendido para estimar estados e parâmetros em processos operando em batelada. Ao final, é mostrada a eficácia dos filtros de partículas em um processo de polimerização ao compará-lo com o filtro de Kalman estendido.

Posteriormente, Chen, Morris e Martin (2008) propuseram uma aplicação ao filtro de partículas com o objetivo de retificar os dados dinâmicos. A formulação do problema de retificação dentro de uma estrutura probabilística de estimação, o filtro de partículas gerou amostras a partir da distribuição *a posteriori* dos estados do sistema, fornecendo uma base para retificar as medidas do processo. Além disso, a metodologia proposta foi capaz de detectar mudanças na operação, completando a tarefa de diagnóstico de falha de processo. A ideia foi aplicada em um sistema dinâmico não linear ilustrativo e a um processo de neutralização de pH.

Schagen *et al.* (2008) utilizaram o controle MPC não linear em um processo de cristalização de carbonato de cálcio em tratamento de água, com a função de determinar os valores das variáveis manipuladas. De forma paralela, há o uso de filtro de partículas com a função de estimar o estado do reator. Mostrou-se que é possível manter o reator com parâmetros operacionais desejáveis em condições de funcionamento variadas.

Kantas, Maciejowski e Lecchini-Visintini (2009) propuseram a utilização de simulação Sequencial de Monte Carlo (SMC) como mecanismo computacional ao tratar de problemas de controle preditivo baseado. Porém, ter laços aninhados fizeram com que o algoritmo proposto apresentasse em sistemas altamente estocásticos um alto custo computacional, o que acaba por impedir sua implementação.

Este fato foi tratado posteriormente por Stahl e Hauth (2011), que trouxeram uma ideia mais básica e com uma implementação mais simples usando uma abordagem semi-estocástica para solucionar um problema de otimização em sistemas estocásticos aplicando dois filtros de partículas – o primeiro destinado à estimativa dos estados, e o segundo para resolver um problema de controle preditivo. A nova abordagem foi denominada PF-MPC e aplicada a um reator de mistura perfeita (CSTR).

Rasoulían e Ricardez-Sandoval (2016) aplicaram uma abordagem estocástica de modelo não linear de controle preditivo em um processo de deposição de filmes finos. Não houve etapa de estimação, porém foi mostrada a eficácia de um tratamento MPC estocástico não linear em minimizar a rugosidade na superfície do filme, respeitando as restrições de atuadores e restrições probabilísticas sobre a espessura final do filme.

4.2 Filtro de Partículas – Controle Preditivo baseado em modelo (PF-MPC)

Segundo Stahl e Hauth (2011) o grande diferencial dessa nova abordagem é a utilização de dois filtros de partículas com funções distintas. Emprega-se um método estocástico para resolver o problema de otimização incorporando os dois filtros de partículas no controle MPC. Enquanto um filtro estima o estado de forma convencional, o outro filtro determina a entrada de controle. A abordagem segue em caráter estocástico visto nas Equações (59) e (60).

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{v}_{k-1}) \quad (59)$$

$$\mathbf{y}_k = g(\mathbf{x}_k, \boldsymbol{\eta}_k) \quad (60)$$

A condição inicial é dada por $x_0 = x_0 + v_{-1}$, f e g são funções que podem ser não lineares e os ruídos \mathbf{v}_{k-1} e $\boldsymbol{\eta}_k$ também podem ser não gaussianos, de tal maneira que a transição de estados e a observação de densidades podem ser escritas respectivamente como: $a_k(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_{k-1})$ e $b_k(\mathbf{y}_k | \mathbf{x}_k)$.

Na referida abordagem de Stahl e Hauth (2011), o controlador MPC em um instante k fixo, as medidas \mathbf{y}_k tornam-se disponíveis para encontrar a entrada de controle ótima \mathbf{u}_k^* . Esse passo é realizado pelo primeiro filtro de partículas, em uma etapa na qual a estimativa da distribuição do filtro é realizada pela aproximação com uma nuvem de partículas. É comum na abordagem de filtro de partículas a utilização da estimativa pontual de tal nuvem para o cálculo do estado real para otimizar o controlador MPC. Um dos diferenciais que a metodologia PF-MPC relata é o envio da nuvem de partículas completa gerada no primeiro filtro, usando como inicialização para o segundo filtro. Para o segundo filtro de partículas, no instante k ,

cada sequência de controle $\bar{\mathbf{u}}_{k:k+N_p}$ para o horizonte $j = k, k+1, \dots, k+N_p$ pode ser vista como a realização de um processo estocástico, no qual $\bar{\mathbf{U}}_{k:k+N_p}$ é determinada pela densidade inicial $\bar{a}_{u,k}(\bar{\mathbf{u}}_k)$ e as densidades de transição $\bar{a}_{u,j}(\bar{\mathbf{u}}_j | \bar{\mathbf{u}}_{j-1})$, fornecidas pelo usuário.

Partindo de uma realização $\bar{\mathbf{u}}_{k:k+N_p}$ para o processo $\bar{\mathbf{U}}_{k:k+N_p}$ torna-se possível obter amostras sucessivas $\bar{\mathbf{x}}_j$ dada $\bar{\mathbf{x}}_{j-1}$ e $\bar{\mathbf{u}}_{j-1}$ para todo o horizonte de predição $j = k, k+1, \dots, k+N_p$, levando em conta a densidade de transição de estado a_j . Nota-se também que o processo $\bar{\mathbf{x}}_{k:k+N_p}$, $\bar{\mathbf{U}}_{k:k+N_p}$ é um processo Markoviano de distribuição inicial e densidade de transição inicial dada pelas Equações (61) e (62).

$$\bar{a}_k(\bar{\mathbf{x}}_k, \bar{\mathbf{u}}_k) d\bar{\mathbf{x}}_k d\bar{\mathbf{u}}_k = \delta_{x_k}(\bar{d}\bar{\mathbf{x}}_k) \bar{a}_{u,k}(\bar{\mathbf{u}}_k) d\bar{\mathbf{u}}_k \quad (61)$$

$$\bar{a}_j(\bar{\mathbf{x}}_j, \bar{\mathbf{u}}_j | \bar{\mathbf{x}}_{j-1}, \bar{\mathbf{u}}_{j-1}) = \bar{a}_{u,j}(\bar{\mathbf{u}}_j | \bar{\mathbf{u}}_{j-1}) \bar{a}_j(\bar{\mathbf{x}}_j | \bar{\mathbf{x}}_{j-1}) \quad (62)$$

As estratégias de controle baseiam-se em fazer com que o processo opere em determinado valor desejado (*setpoint*). Para esta etapa, o mesmo deve ser considerado também. Sendo assim, a função objetivo determinada pelos autores do PF-MPC com a finalidade de comparar o estado $\bar{\mathbf{x}}_j$ com estes valores nominais \mathbf{s}_j , como pode ser visualizado na Equação (63).

$$J = \sum_{j=k+1}^{k+N_p} \left\| \mathbf{s}_j - \bar{\mathbf{x}}_j \right\|_{\mathbf{R}}^2 \quad (63)$$

Uma escolha natural para essa função objetivo, neste tipo de problema, é a densidade gaussiana, conforme expressa na Equação (64).

$$J = \bar{b}_j(\mathbf{s}_j | \bar{\mathbf{x}}_j, \bar{\mathbf{u}}_j) = \frac{1}{(2\pi)^{n/2} |\mathbf{R}|^{-1/2}} \exp \left\| \mathbf{s}_j - \bar{\mathbf{x}}_j \right\|_{\mathbf{R}}^2 \quad (64)$$

Dessa forma, pode-se criar um modelo de espaço estado geral dado pelas densidades de transição $\bar{a}_j(\bar{\mathbf{x}}_j, \bar{\mathbf{u}}_j | \bar{\mathbf{x}}_{j-1}, \bar{\mathbf{u}}_{j-1})$ e de observação $\bar{b}_j(\mathbf{s}_j | \bar{\mathbf{x}}_j, \bar{\mathbf{u}}_j)$.

Segundo Stahl e Hauth (2011), iniciar o segundo filtro a partir da nuvem de partículas do primeiro para o segundo permite o cálculo sucessivo para cada j como uma aproximação para a distribuição de “suavização conjunta” $p(d\bar{\mathbf{x}}_{k:j}, d\bar{\mathbf{u}}_{k:j} | \mathbf{s}_{k+1:j})$.

Isso leva a uma aproximação de marginalização ao excluir os valores de nas partículas, conforme mostrado na Equação (65):

$$p(d\bar{\mathbf{u}}_{k:j} | \mathbf{s}_{k+1:j}) = \int_{\mathbf{x}_{k:j}} p(d\bar{\mathbf{x}}_{k:j}, d\bar{\mathbf{u}}_{k:j} | \mathbf{s}_{k+1:j}) \quad (65)$$

Uma vez que a distribuição anterior é dada através de uma aproximação de partículas, a marginalização da Equação (65) é facilmente obtida apenas descartando os valores de $\bar{\mathbf{x}}_j$. Sendo assim, para todo o horizonte de predição $j = k + N_p$, obtém-se uma aproximação para a distribuição dada por:

$$p(d\bar{\mathbf{u}}_{k:k+N_p} | \mathbf{s}_{k+1:k+N_p}) \quad (\text{STAHL; HAUTH, 2011}).$$

Excluindo todos os $\bar{\mathbf{u}}_j$, com exceção do primeiro, é possível obter em um contexto Bayesiano a denominada distribuição posterior para o controle \mathbf{u}_k , tendo como partida valores nominais $\mathbf{s}_{k+1:k+N_p}$, sendo nesse sentido ótimo para as densidades a_j e b_j . Com isso, observa-se que o segundo filtro de partículas estima uma aproximação para a distribuição do próximo controle \mathbf{u}_k , de forma a atingir valores preestabelecidos $\mathbf{s}_{k+1:k+N_p}$, como é um objetivo de uma estratégia de controle. Dessa forma, uma estimativa pontual \mathbf{u}_k^* pode ser calculada e, em seguida aplicada ao sistema até a próxima etapa de tempo, onde todo procedimento é repetido. Essa estratégia pode ser vista na Figura 8 abaixo, onde trata o esquema do PF-MPC de forma simplificada.

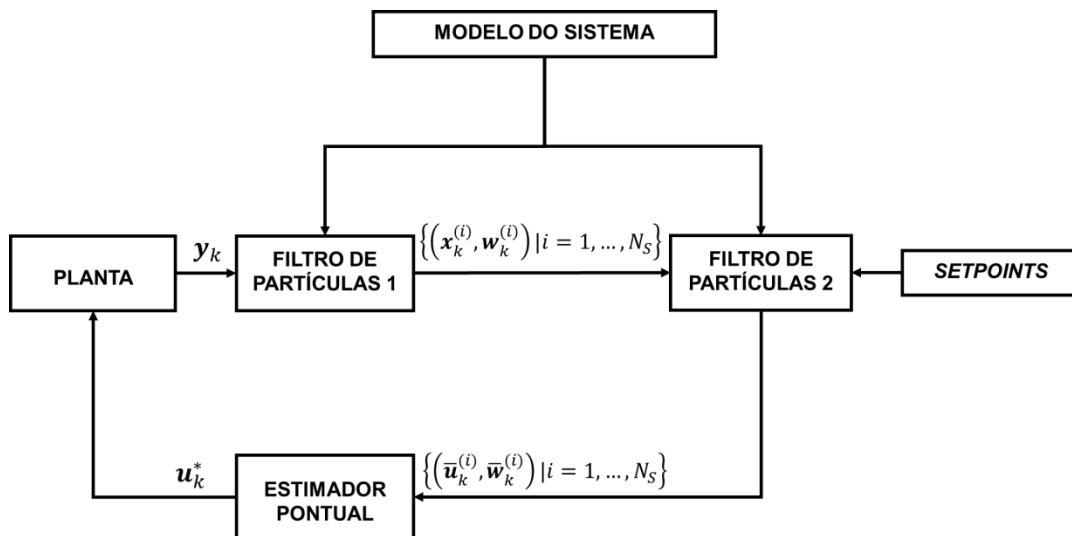


Figura 8 - Esquema do ciclo de controle PF-MPC. Fonte: Stahl e Hauth (2011), modificado pelo autor.

Restrições nas entradas são tratadas por Stahl e Hauth (2011). As restrições suaves são aquelas que se encontram em uma região específica na maioria das vezes, porém pode haver violação desse limite em um dado momento, sendo esse tipo de restrição definida por meio de uma equação de transição de entradas, conforme mostra a Equação (66). As restrições conhecidas como “caixa” determinam que as entradas necessitem estar contidas no intervalo $[a, b]$, conforme mostra a Equação (67) (STAHL; HAUTH, 2011).

$$\bar{\mathbf{u}}_j = \bar{\mathbf{v}}_{k-1} \text{ com } \bar{\mathbf{v}}_{k-1} \sim N(0, \sigma^2) \quad (66)$$

$$\bar{\mathbf{u}}_j = \bar{\mathbf{v}}_{k-1} \text{ com } \bar{\mathbf{v}}_{k-1} \sim U(a, b) \quad (67)$$

Nessas Equações σ^2 , a e b são a variância e os limites da região de restrição.

O método apresentado é composto das etapas listadas abaixo, com o passo a passo de como o algoritmo deve ser implementado do segundo filtro de partículas com aplicação em controle preditivo.

Passo 1 - Inicialização: Geração das partículas iniciais $\left\{ \bar{\mathbf{u}}_k^{(i-)} \right\}_{i=1}^N$, a partir da distribuição $\bar{\mathbf{u}}_k^{(i-)} = \mathbf{u}_{k-1} + \mathbf{v}$, $\mathbf{v} \sim N(0, \Sigma \mathbf{u})$, considerar as partículas $\left\{ \mathbf{x}_k^{(i-)} \right\}_{i=1}^N$, bem como os pesos associados $\left\{ \mathbf{w}_k^{(i)} \right\}_{i=1}^N$ do PF, como condição inicial do PF-MPC $\bar{\mathbf{x}}_k^{(i-)} = \mathbf{x}_k^{(i)}$ e $\bar{\mathbf{w}}_k^{(i)} = \mathbf{w}_k^{(i)}$;

Passo 2 – Iteração: $j = k + 1, \dots, N_p$

a) Geração das partículas das entradas $\left\{ \bar{\mathbf{u}}_{k+j}^{(i)} \right\}_{i=1}^{N_p}$ a partir da distribuição

$$\bar{\mathbf{u}}_{k+j}^{(i)} = \bar{\mathbf{u}}_{k+j-1}^{(i)} + \mathbf{v}, \mathbf{v} \sim N(0, \Sigma \mathbf{u});$$

b) Geração das partículas dos estados por meio da função

$$\bar{\mathbf{x}}_{k+j}^{(i)} = \phi\left(\bar{\mathbf{x}}_{k+j-1}^{(i)}, \bar{\mathbf{u}}_{k+j-1}^{(i)}, \xi_{k+j-1}^{(i)}\right);$$

c) Avaliar a probabilidade usando uma trajetória de metas s_{k+j} e atualizar os pesos, de modo que seja possível calcular os pesos não normalizados:

$$\bar{\mathbf{w}}_{k+j}^{(m)} = \bar{\mathbf{w}}_{k+j-1}^{(m)} h_p\left(s_{k+j} | \bar{\mathbf{x}}_{k+j}^{(m)}\right) \text{ e, normalizar os pesos de acordo com:}$$

$$\bar{\mathbf{w}}_{k+j}^{(i)} = \bar{\mathbf{w}}_{k+j}^{(i)} / \sum_{i=1}^N \bar{\mathbf{w}}_{k+j}^{(i)};$$

- d) Geração das partículas *a posteriori* $\left\{ \mathbf{u}_{k+j}^{-(i)} \right\}_{i=1}^N$, com base nas informações de ponderação e estratégia de reamostragem, e recalcular os pesos, da seguinte forma: $w_k^i = 1/N$;
- e) Registrar uma sequência de entradas $\mathbf{u}_{k+j}^{-(i)}$, e repetir o processo de $j=1$ a $j = N_p$;

Passo 3 – Iteração: Determinar a entrada de controle ótima u_{k+1} , a partir de:

$$\left\{ \mathbf{x}_{k+1:k+N_p}^{-(i)}, \mathbf{u}_{k+1:k+N_p}^{-(i)}, \mathbf{w}_{k+1:k+N_p}^{(i)} \right\}.$$

4.3 Filtro de Kalman *Unscented* – Controle Preditivo baseado em modelo (UKF-MPC)

O UKF – MPC é um algoritmo de controle e monitoramento de processos semelhante ao PF-MPC, entretanto utiliza o Filtro de Kalman *Unscented* (UKF) para estimação e cálculo da ação de controle ótima, considerando restrições apenas nas entradas do sistema.

A diferença principal do UKF-MPC para o PF-MPC está nos estimadores utilizados, na informação inicial que o filtro necessita e na informação de saída do mesmo. No algoritmo UKF-MPC, o primeiro filtro recebe as informações de medição \mathbf{y}_k , juntamente com a estimativa do estado e a covariância no instante de tempo anterior.

A partir de etapas de predição e correção, o UKF1 projeta à estimativa e a covariância no tempo atual. Essas informações são enviadas a um segundo filtro, UKF2, que atua como um controlador preditivo, realizando a estimação e enviando para a planta a ação de controle ótima. A Figura 9 apresenta um esquema para o UKF – MPC.

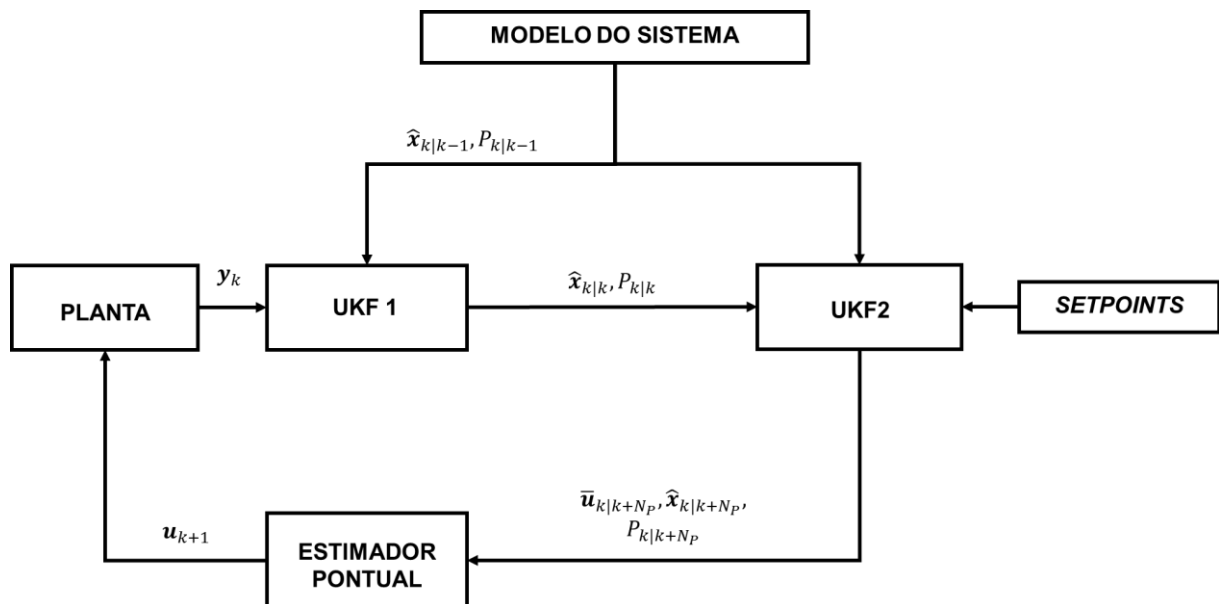


Figura 9 - Esquema de controle UKF-MPC. Fonte: próprio autor.

4.4 Filtro de Partículas Restrito – Controle Preditivo baseado em modelo (CPF-MPC)

O esquema de controle preditivo baseado em modelo associado ao filtro de partículas restrito engloba dois filtros amostragem por importância e reamostragem sequencial (*Sequential Importance Resampling – SIR*) e atuando em conjunto no controle e monitoramento de processos. Considera-se, além das restrições sobre as variáveis manipuladas (problema abordado pelo PF-MPC), uma etapa de busca pela ação de controle como entrada do segundo filtro para a geração da ação de controle ótima e sistematicamente restrições sobre as variáveis de saídas estimadas, as quais incluem os estados e as variáveis controladas, configurando no algoritmo CPF-MPC (do inglês, *Constrained Particle Filter – Model Predictive Control*).

As informações de medição são enviadas ao primeiro PF, que reduz o ruído de medição e estima os estados do processo. Verifica-se, então, se essas estimativas estão dentro da região de restrição requerida. Caso respeitem os limites superior e inferior de restrição, o Filtro 1 envia as informações para o segundo PF. Caso contrário, uma etapa de otimização e reamostragem é realizada com o intuito de projetar a estimativa dos estados que violaram as restrições para a região de restrição.

Na etapa de otimização e reamostragem, inicialmente as partículas *a posteriori* são divididas em dois grupos: partículas “boas” e partículas “ruins”. O primeiro é constituído pelas partículas que se encontram dentro da região de restrição, e o segundo por aquelas que estão fora do limite de restrição. As estimativas que violaram as restrições são projetadas para dentro da região permitida por uma função que minimiza o erro entre o valor estimado e o valor medido considerando os limites de restrição. Entretanto, apenas considerar a projeção da estimativa compromete a geração das partículas *a posteriori*, uma vez que todos os cálculos após essa etapa são realizados baseando-se na hipótese de distribuição Gaussiana. Para evitar essa situação, as partículas *a posteriori* “ruins” são escolhidas de forma aleatória e projetadas para dentro da região de restrição. Cada partícula projetada passa a fazer parte das partículas “boas”. Os dois novos conjuntos de partículas são utilizados para o cálculo da nova estimativa. Esse passo é iterativo e realizado até que todas as partículas “ruins” se tornem “boas” ou que a nova estimativa obtenha um desempenho melhor (com base na distância em que se encontram em relação aos limites da região de restrição) do que a projeção da estimativa.

Com a estimativa dentro da região de restrição, as novas partículas *a posteriori* são enviadas, juntamente com os pesos normalizados e a estimativa dos estados ao segundo PF que realiza o cálculo da ação de controle ótima. Nessa etapa, as variáveis manipuladas são estimadas e os estados recuperados, obtendo-se assim a ação de controle ótima. Verifica-se, assim como para o Filtro 1, se os valores dos estados recuperados se encontram dentro da região de restrição, realizando o mesmo procedimento já apresentado em caso de violação. Por fim, as manipulações preditas pelo Filtro 2 são aplicadas no processo, possibilitando o controle das variáveis, mesmo diante de perturbações nas condições de entrada do processo e diante de alterações nos *setpoints*.

Um esquema para o CPF-MPC pode ser visto pela Figura 10.

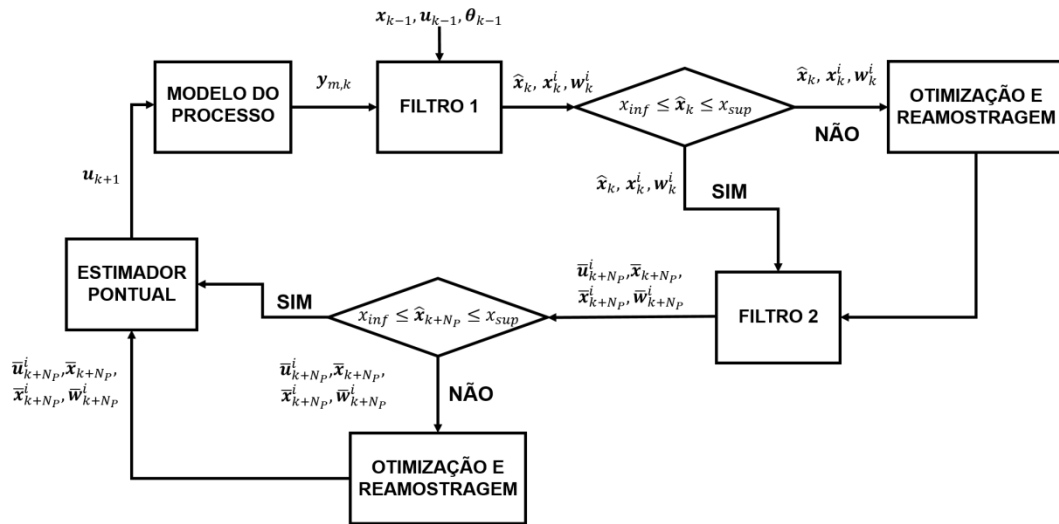


Figura 10 - Esquema de controle proposto CPF - MPC. Fonte: próprio autor.

4.5 Filtro de Kalman *Unscented* Restrito – Controle Preditivo baseado em modelo (CUKF-MPC)

Assim como no esquema CPF – MPC, o CUKF – MPC é um algoritmo de controle e monitoramento de processos que leva em consideração as restrições nos estados estimados pelo filtro, em que o Filtro de Kalman *Unscented* (UKF) é utilizado como ferramenta estimadora.

Nesse algoritmo, dois Filtros UKF são utilizados em conjunto. O Filtro UKF estima através de duas etapas: predição ou previsão e atualização ou correção. O primeiro filtro (UKF1) recebe as informações de medição juntamente com as informações da estimativa dos estados e covariância do tempo anterior, este filtro realiza a projeção da estimativa e da covariância no tempo atual. O segundo filtro (UKF2) recebe como informação inicial a condição de saída do UKF1 e as informações de medição e estima além dos estados, também a entrada de controle ótima.

Caso a estimativa ou as informações de medição se encontrem fora dos limites da região de restrição, etapas de otimização são utilizadas após a previsão, correção e nas informações de medição com a finalidade de garantir que as restrições sejam obedecidas, projetando os valores que violaram esses limites para dentro da região viável. O esquema de controle considerando essa verificação quanto à violação da região de restrição é semelhante ao UKF-MPC, a mudança acontece nos algoritmos dos Filtros, conforme pode ser visualizado pela Figura 11.

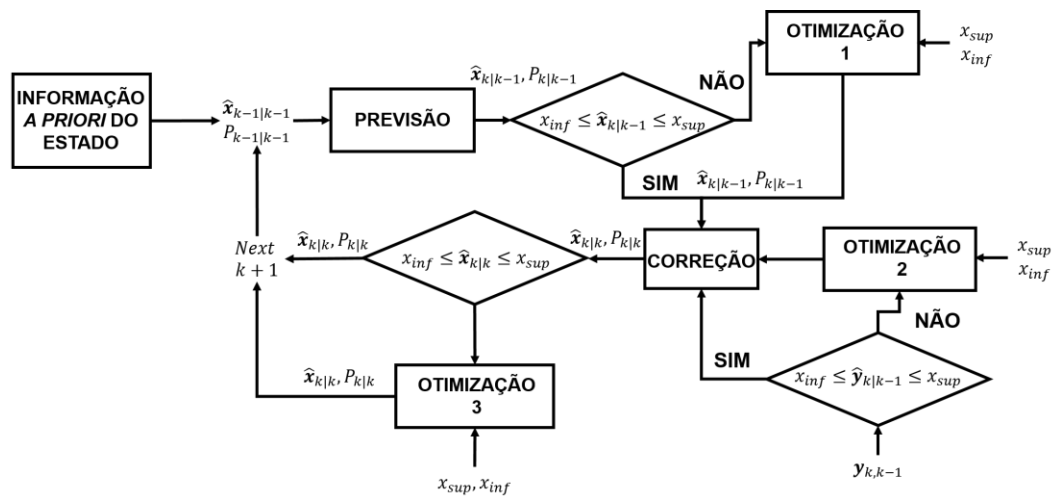


Figura 11 - Esquema do filtro para o algoritmo CUKF proposto. Fonte: próprio autor.

As otimizações que ocorrem quando a estimativa *a priori*, a estimativa *a posteriori* e as informações de medição violam a restrição visando uma projeção das mesmas para uma região válida é detalhada abaixo:

Otimização 1: Após a etapa de predição, são disponibilizadas a estimativa dos estados e a covariância *a priori*. Essa estimativa, caso viole os limites das restrições é projetada para dentro da região permitida pela minimização de uma função que considera o próprio valor da estimativa *a priori* e os limites de restrição.

Otimização 2: A medida disponível também é verificada e caso viole os limites da região de restrição é projetada para dentro da região desejada por meio da minimização de uma função que considera a medição e os limites da região de restrição.

Otimização 3: A parte final do algoritmo UKF calcula o ganho de Kalman e com ele uma correção para a estimativa e covariância *a posteriori*. Desse modo, é verificado se essa estimativa viola as restrições, caso essa hipótese se confirme é realizada uma terceira otimização que projeta a estimativa dos estados para dentro da região de restrição. Essa otimização é realizada pela minimização de uma função que considera o valor dessa estimativa e os limites da região desejada.

UKF 2 repete esse mesmo procedimento, porém nesse filtro estima-se a entrada de controle ótima e envia a mesma para a planta, a fim de fornecer a ação ótima de controle do controlador MPC.

4.6 Comentários Finais

Neste capítulo foi apresentado um apanhado teórico referente à aplicação de uma formulação na qual o filtro de partículas é utilizado como resolução de um problema de otimização estocástica. O presente capítulo também trouxe uma revisão da literatura. Pode-se observar que as estratégias de controle avançado juntamente com a aplicação de estimadores de estados vêm ganhando destaque no cenário acadêmico (principalmente quando se trata de modelo de processos não lineares e com incertezas de caráter não gaussiano, a maioria dos sistemas reais existentes).

Neste trabalho de Dissertação é proposta a aplicação de estimadores de estados, especificamente o filtro de partículas com estimação restrita, juntamente com o controle preditivo MPC para a regulação de um reator CSTR e o reator de Van der Vusse. Além de uma aplicação do método PF-MPC proposto por Stahl e Hauth (2011) para um circuito de beneficiamento de minérios.

5 CONTROLE PREDITIVO COM FILTRO DE PARTÍCULAS RESTRITO E APLICAÇÃO EM ESTUDOS DE CASO

Este capítulo dividiu-se em quatro seções, as quais abordam as etapas de apresentação dos novos algoritmos propostos neste trabalho, bem como o detalhamento dos três estudos de caso no qual as técnicas foram aplicadas.

5.1 Controle Preditivo com estimação restrita

A proposta CPF-MPC foi avaliada nesta Dissertação a partir de dois estudos de caso simulados. No primeiro estudo, considerou-se um reator CSTR e o desempenho do algoritmo CPF-MPC foi comparado com o PF-MPC e com os esquemas em que o Filtro de Kalman *Unscented* foi utilizado como ferramenta para estimação e cálculo da ação de controle ótima (o UKF-MPC e o CUKF-MPC). O segundo estudo de caso considera um problema de controle de referência (*benchmark*): um reator CSTR com cinética de van der Vusse (ENGELL; KLATT, 1993). Este sistema não linear e muito instável foi considerado para demonstrar o potencial do CPF-MPC em face de um cenário operacional mais complexo.

Por fim, como último estudo de caso, foi utilizada a abordagem PF-MPC de Stahl e Hauth (2011) para um circuito de fragmentação e classificação de minério de ferro, comparando o seu desempenho com o de um controlador PI, tradicionalmente utilizado para este processo. Este circuito foi selecionado por ser um problema multivariável, de alta dimensão e complexo, além de contar com reciclagem de materiais, o que contribui para aumento de sua instabilidade.

Além da incorporação das restrições, vista no algoritmo CPF-MPC, foi adicionada uma etapa de cálculo otimizado da variável manipulada, que serve como condição inicial para o segundo filtro na busca pela ação de controle ótima. Esse valor está representado em alguns gráficos como a variável manipulada “alvo” e consiste na busca pelo valor da variável manipulada relacionado ao valor mínimo da função objetivo.

A fim de solucionar os problemas inversos busca-se sempre o uso de dados experimentais reais, pois, desse modo pode ser verificado se o modelo matemático utilizado representa de forma adequada os fenômenos envolvidos no processo em

estudo. Contudo, nem sempre se tem acesso a estes dados, sendo assim torna-se usual, a geração de dados experimentais sintéticos por meio da adição de ruídos pseudoaleatórios aos valores calculados com o modelo ao empregar valores exatos das incógnitas que se deseja determinar, conforme mostra a Equação (68) (SOARES, 2013).

$$\mathbf{y}_{\text{exp}} = \mathbf{y}_{\text{exato}} + \lambda \sigma \quad (68)$$

Em que \mathbf{y}_{exp} representa o valor do dado experimental “sintético”, $\mathbf{y}_{\text{exato}}$ o valor exato das variáveis oferecido pelo modelo, λ é um número aleatório gerado dentro do intervalo $[-1, 1]$ e σ simula o desvio padrão dos erros experimentais.

Essa abordagem que utiliza o mesmo modelo matemático para geração de medidas experimentais e para a resolução do problema inverso é denominada crime inverso (do inglês *inverse crime*). Mesmo não permitindo a avaliação do modelo matemático do problema direto quanto à representação dos fenômenos envolvidos no processo estudado, esta abordagem permite uma boa avaliação do método utilizado para solução do problema inverso, pois, há um conhecimento prévio da solução que se deseja obter ($\mathbf{y}_{\text{exato}}$) e é também exercido o controle do nível de ruído presente no dado experimental. A maneira mais usual de atenuar o crime inverso consiste na utilização de um método para a solução do problema direto e outro para a solução do problema inverso (SILVA; BECCENERI, 2012).

Nesta Dissertação, com o intuito de obter métodos diferentes para solução dos problemas direto e inverso, dados sintéticos experimentais são gerados ao acrescentar ruído aleatório aos dados calculados, simulando os dados experimentais.

Os parâmetros dos filtros de partículas, como o número de partículas, o desvio padrão da função de probabilidade do segundo filtro foram ajustados ao longo das simulações. O desempenho da estratégia de controle preditivo associado aos filtros de partículas foi avaliado pelo erro médio quadrático (RMS) e pelo somatório do erro absoluto (AES) e as melhores configurações foram mostradas para cada sistema estudado, selecionando-as para o esquema de controle proposto. Além disso, também foi utilizada uma região de credibilidade para a estimativa de 99%, calculada para cada tempo de amostragem conforme as Equações (71) e (72) para verificar se a proposta reduzia os efeitos das incertezas de medição. L_{inf} e L_{sup}

contêm os valores que não possuem diferença estatística dentro de uma região de credibilidade de 99% para os estados estimados.

$$RMS = \sqrt{\frac{1}{N_t} \sum_{i=1}^N (\mathbf{y}_k - \mathbf{y}_{est})^2} \quad (69)$$

$$AES = \sum_{i=1}^N |\mathbf{y}_{set} - \mathbf{y}_k|^2 \quad (70)$$

$$L_{inf} = \mathbf{y}_k - 2.576 \cdot \sigma_{est} \quad (71)$$

$$L_{sup} = \mathbf{y}_k + 2.576 \cdot \sigma_{est} \quad (72)$$

Nas equações acima, N_t representa o tamanho do vetor do tempo, \mathbf{y}_{set} o *setpoint* da variável controlada em questão. O número de partículas é definido pela letra N , L_{inf} e L_{sup} são os limites do intervalo de credibilidade. \mathbf{y}_k e \mathbf{y}_{est} são as variáveis exatas e os estados estimados ou saídas estimados, respectivamente.

Os esquemas de controle devem, ao longo dos testes, minimizar estes índices proporcionando menor erro em relação ao *setpoint* definido (AES) e um menor em relação ao valor exato da variável estimada (RMS).

Uma maneira bem simples de estabelecer comparações e tomar decisões baseia-se na construção de intervalos de confiança para as variáveis consideradas. Por exemplo, se α e β são as grandezas comparadas (médias ou variâncias amostrais, entre outras), e as mesmas possuem intervalos iguais a $\alpha_1 < \alpha < \alpha_2$ e $\beta_1 < \beta < \beta_2$ para um grau de confiança p% especificado. Desse modo, admitindo que $\alpha_1 < \beta_1$, as grandezas α e β são distintas com o grau de confiança desejado se $\alpha_2 < \beta_1$, ou seja, se não há interseção entre os intervalos considerados (SCHWAAB; PINTO, 2007).

A fim de verificar se a variabilidade é a mesma para os três grupos, utilizou-se o teste F. Desse modo, ao considerar uma das variáveis de interesse com média μ e variância σ^2 , o teste possibilitou calcular dois estimadores de σ^2 : S_E^2 que representa a dispersão entre os grupos (do inglês, *between*) e S_D^2 é a dispersão dentro dos grupos (do inglês, *within*). Pode-se mostrar que o quociente S_E^2 / S_D^2 tem distribuição F com (n-1) e 3 (n-1) graus de liberdade (n representa o número de observações e 3

é a quantidade de grupos de análise). O cálculo de S_E^2 e S_D^2 é dado pelas Equações (73) e (74) (MONTGOMERY; RUNGER, 2003).

$$S_E^2 = N \left[\frac{\sum \mathbf{x}_i^2 - \frac{(\sum \bar{\mathbf{x}}_i)^2}{k}}{k-1} \right] \quad (73)$$

$$S_D^2 = \frac{(N_1-1)S_1^2 + (N_2-1)S_2^2 + \dots + (N_k-1)S_k^2}{(N_1-1) + (N_2-1) + \dots + (N_k-1)} \quad (74)$$

Em que k representa o número de grupos e N é o número de observações. Sendo $F_{calculado} = S_E^2 / S_D^2$, se o valor de $F_{calculado}$ não estiver dentro do intervalo $F_{tabelado,1} < F < F_{tabelado,2}$ (limites obtidos pela tabela F com os valores de k e N), há evidências de que existem diferenças estatísticas significativas entre os valores no nível de significância escolhido (SCHWAAB; PINTO, 2007).

Os modelos foram resolvidos usando o método *backward-difference* e os algoritmos foram implementados usando o software Matlab em um computador com processador intel® Core i5™.

5.2 Estudo de Caso 1: Reator CSTR

O primeiro estudo de caso consiste em um reator de tanque agitado contínuo (CSTR) não isotérmico com uma reação de primeira ordem $A \rightarrow B$, como mostrado na Figura 12.




Figura 12 - Esquema do reator CSTR. Fonte: Stahl e Hauth (2011), modificada pelo autor.

Algumas considerações são relevantes na formulação matemática do modelo do processo. Por exemplo, foi considerado que o reator é perfeitamente misturado e que a quantidade de calor retido na parede é insignificante. Além disso, qualquer perda de calor para o ambiente foi desconsiderada. Um fluxo de líquido circunda o reator e promove o seu aquecimento ou arrefecimento, mantendo a concentração no valor desejado.

Para o modelo, a temperatura T_r é considerada uma variável de medição fácil e a concentração C_a , o estado controlado, é uma variável latente que precisa ser estimada. A variável manipulada é a temperatura da camisa T_j , que ajusta a temperatura do reator. Com base nestes pressupostos, os balanços de massa e energia para o CSTR podem ser expressos pelas Equações (75) e (76).

$$\frac{dT_r}{dt} = \frac{(-\Delta H)}{\rho C_p} k_0 C_a e^{\frac{-E}{RT_r}} + \frac{F}{V_r} (T_f - T_r) + \frac{UA_r}{\rho C_p V_r} (T_j - T_r) \quad (75)$$

$$\frac{dC_a}{dt} = -k_0 C_a e^{\frac{-E}{RT_r}} + \frac{F}{V_r} (C_{af} - C_a) \quad (76)$$

A Tabela 1 apresenta as condições iniciais, propriedades físicas e parâmetros das equações do modelo.

Tabela 1 - Parâmetros, condições iniciais e propriedades físicas para o CSTR.

$U_r = 68 \text{ kcal}/(\text{min} \cdot \text{m}^2 \cdot ^\circ\text{C})$	$E = 8314 \text{ kJ/kmol}$
$A_r = 0,7 \text{ m}^2$	$F = 0,0036 \text{ m}^3/\text{min}$
$V_r = 0,24 \text{ m}^3$	$T_i = 347,15 \text{ K (74 } ^\circ\text{C)}$
$C_p = 1 \text{ kcal}/(\text{kg} \cdot ^\circ\text{C})$	$C_a(1) = C_a(\text{set}) = 5,364 \text{ kmol}/\text{m}^3$
$k_0 = 3,64 \times 10^6 \text{ min}^{-1}$	$C_{af} = 25 \text{ kmol}/\text{m}^3$
$\Delta H = 8000 \text{ kcal/mol}$	$T_r(1) = 333,15 \text{ K (60 } ^\circ\text{C)}$
$E = 49884 \text{ kJ/kmol}$	$T_f = 300,15 \text{ K (27 } ^\circ\text{C)}$

Fonte: Kittisupakorn e Hussain (2000), modificada pelo autor.

As medidas de temperatura simuladas foram obtidas a partir da saída do modelo. Aos dados simulados, foram acrescentados ruídos aleatórios que seguem uma distribuição gaussiana com média zero e desvio padrão de 2% do valor exato simulado. Dessa forma, as medidas simuladas da temperatura para o problema de estimação foram obtidas de acordo com a Equação (77).

$$T_m = T_{\text{exato}} + N(0, 0.02 \cdot T_{\text{exato}}) \quad (77)$$

Os dois filtros de partículas SIR aninhados realizaram a estimativa da concentração de reagente a partir da medida da temperatura disponível e promoveram o controle da operação. Valores de 10, 50 e 100 partículas foram utilizadas para avaliar a melhor configuração do CPF-MPC, com os valores de desvio padrão da função de verossimilhança do segundo filtro de 0,1°C, 0,5°C e 5°C. Considerou-se que a função de densidade a priori é normal, com desvio padrão de 1% e 2% da condição inicial para a concentração e temperatura, respectivamente. A função de verossimilhança é considerada normal com desvio padrão igual a 1°C, escolhido de forma arbitrária.

Visando uma eficiência no desempenho do controle, as estratégias de controle, abordada nos algoritmos PF-MPC, CPF-MPC, UKF-MPC e CUKF-MPC, foram implementadas com um horizonte de previsão de 8 min, escolhido de forma aleatória, considerando restrições na temperatura do reator e na temperatura da jaqueta que circunda o mesmo. O tempo de amostragem escolhido foi de 1 min, consistente com o tempo necessário para obtenção de medidas de qualidade em um processo real.

A fim de avaliar a eficiência do algoritmo de controle CPF-MPC, o desempenho do mesmo foi comparado ao PF-MPC e entre algoritmos de controle em que o estimador escolhido foi o UKF, denominados de UKF-MPC e CUKF-MPC.

Além dos critérios visuais obtidos pela análise do comportamento gráfico de cada simulação realizada, o desempenho dos algoritmos de controle com estimação foi

avaliado com base no erro médio quadrático (RMS), parâmetro mais utilizado na literatura ao se considerar estimação Bayesiana. Outro critério utilizado para avaliar o desempenho das estratégias de controle foi a soma do erro absoluto (AES, do inglês *Absolute Error Sum*).

O desempenho do CPF-MPC foi comparado com os demais esquemas, considerando que as restrições na temperatura do reator assumiriam valores nos quais o processo poderia constantemente ultrapassar, em virtude das mudanças programadas no *setpoint* da concentração. Para tal avaliação foi realizado um teste servo de mesma intensidade de variação na concentração do reator para as duas simulações, a partir do instante de tempo de 150 min. Ao que diz respeito às restrições, elas foram consideradas em uma faixa curta de valores que acompanharam em forma de túnel a mudança do tipo rampa realizada no *setpoint*, ou seja, esses limites ($T_r(\text{inf})$ e $T_r(\text{sup})$), iniciaram em um valor inicial e decresceram ou tiveram seus valores acrescidos a uma quantidade constante consoante a realização do teste de perturbação de C_a . Um esquema de como as restrições e o *setpoint* podem se comportar pode ser visualizado pela Figura 13.




Figura 13 - Esquema de resposta do comportamento das restrições na temperatura do reator de acordo com a perturbação realizada no *setpoint*.

A Tabela 2 apresenta as condições utilizadas para os testes realizados em cada uma das simulações.

Tabela 2 - Condições para o teste, considerando restrições "túnel".

Esquema de Controle	N	T _r (inf)	T _r (sup)	ΔC _a (set)	ΔT _r (inf) e ΔT _r (sup)
CPF-MPC	100	332	334	20%Ca _{sp}	0,3
CUKF-MPC	-	332	334	20%Ca _{sp}	0,3
PF-MPC	100	332	334	20%Ca _{sp}	0,3
UKF-MPC	-	332	334	20%Ca _{sp}	0,3

$\Delta T_r(\text{inf})$ e $\Delta T_r(\text{sup})$ são os incrementos ou decréscimos ao longo de cada instante de tempo em que a variável controlada será exposta no período no qual ocorre a perturbação programada do desvio do *setpoint* da concentração do reator.

5.3 Estudo de Caso 2: Reator de Van der Vusse

O reator de tanque agitado contínuo (CSTR) utilizado na cinética de van der Vusse é amplamente explorado no contexto de controle de processos não lineares como um problema de referência (do inglês *benchmarck*), muito por causa das suas características peculiares: comportamento não linear dependente do *setpoint* e inversão do sinal de ganho de estado estacionário em condições operacionais ótimas (máxima concentração do produto desejado). Além disso, como representam uma classe de reator onde ocorre resfriamento, é muito interessante do ponto de vista industrial (OLIVEIRA, 1996; PRAXEDES *et al.*, 2008; MAGALHÃES, 2010; GRANZOTTO; OLIVEIRA-LOPES, 2014).

O processo consiste em um reator CSTR com uma camisa de arrefecimento no qual o ciclopentenol (B) é produzido a partir do ciclopentadieno (A). Também ocorre formação de subprodutos indesejados como o ciclopentanadiol (C) e o dicitlopentadieno (D) (ENGELL; KLATT, 1993). A cinética envolve reações em série e em paralelo, como descritas segundo as reações representadas nas Equações (78) e (79) (PRAXEDES *et al.*, 2008).



A alimentação contém apenas o reagente A com concentração C_{af} e temperatura T_f , e a remoção de calor pode ser obtida por uma circulação de fluido refrigerante em uma camisa de troca térmica que permite a manutenção da temperatura no interior do reator. Considerando a densidade constante em todo reator juntamente com o controle de nível ideal, a dinâmica do sistema pode ser descrita pelas seguintes equações diferenciais não lineares em forma de balanço material para os reagentes A e B e balanço energético para as temperaturas do reator e da camisa, respectivamente, expressadas pelas Equações (80) - (83) (CHEN; KREMLING; ALLGOWER, 1995; ENGELL; KLATT, 1993).

$$\frac{dC_a}{dt} = \frac{F}{V_r} (C_{af} - C_a) - k_1(T_r)C_a - k_3(T_r)C_a^2 \quad (80)$$

$$\frac{dC_b}{dt} = -\frac{F}{V_r} C_b + k_1(T_r)C_a - k_2(T_r)C_b \quad (81)$$

$$\begin{aligned} \frac{dT_r}{dt} = & -\frac{F}{V_r} (T_f - T_r) + \frac{k_w A_r}{\rho C_p V_r} (T_j - T_r) \\ & - \frac{1}{\rho C_p} \left[k_1(T_r)C_a \Delta H_1 + k_2(T_r)C_b \Delta H_2 + k_3(T_r)C_a^2 \Delta H_3 \right] \end{aligned} \quad (82)$$

$$\frac{dT_j}{dt} = \frac{Q_j}{m_j C_{p_j}} + \frac{k_w A_r}{m_j C_{p_j}} (T_r - T_j) \quad (83)$$

As concentrações dos elementos A e B são C_a e C_b , respectivamente. A temperatura do reator é dada por T_r e a temperatura da jaqueta de resfriamento é T_j ; V_r é o volume do reator, C_p e ρ são o calor específico e a densidade, respectivamente. ΔH Representa o calor da reação e k_i as constantes cinéticas, que são dependentes de T_r e definidas via equação de Arrhenius, conforme descrita pela Equação (84) (CHEN; KREMLING; ALLGOWER, 1995). O índice numérico indica: 1 – reação principal; 2 – reação em série e 3 – reação em paralelo e o subscrito j , as propriedades do fluido da jaqueta de resfriamento; m representa o fluxo de massa e Q o calor removido, ambos relacionados à jaqueta.

$$k_i(T_r) = k_{i0} \exp\left(\frac{E_i}{T_r(K)}\right), i = 1, 2, 3 \quad (84)$$

Os parâmetros cinéticos das reações juntamente com as propriedades do reator e da camisa são dados pela Tabela 3.

Tabela 3 - Propriedades físicas e parâmetros para o reator de Van der Vusse.

$k_{10} = 1,287 \times 10^{12} \text{h}^{-1}$	$\Delta H_3 = - 41,85 \text{ kJ/mol}$
$k_{20} = 1,287 \times 10^{12} \text{h}^{-1}$	$\rho = 0,9342 \text{ kg/m}^3$
$k_{30} = 9,043 \times 10^9 \text{L}^* \text{mol}^{-1} \cdot \text{h}^{-1}$	$C_p = 3,01 \text{ kJ}/(\text{kg} \cdot \text{K})$
$E_1 = - 9758,3 \text{ K}$	$k_w = 4032 \text{ kJ}/(\text{kg} \cdot \text{m}^2 \cdot \text{K})$
$E_2 = - 9758,3 \text{ K}$	$A_r = 0,215 \text{ m}^2$
$E_3 = - 8560 \text{ K}$	$V_r = 10 \text{ L}$
$\Delta H_1 = 4,2 \text{ kJ/mol}$	$m_j = 5 \text{ kg}$
$\Delta H_2 = - 11 \text{ kJ/mol}$	$C_{pj} = 2 \text{ kJ}/(\text{kg} \cdot \text{K})$

Fonte: Kulikov e Kulikova, 2014, p. 760.

Para as etapas de simulação, estimação e controle, considerou-se as condições ótimas do processo como sendo as condições iniciais para as equações diferenciais, como pode ser observado na Tabela 4.

Tabela 4 - Condições iniciais para os estados e entradas.

$C_{af} = 5,1 \text{ mol/L}$	$C_a(0) = 2,14 \text{ mol/L}$
$T_f = 104,9 \text{ }^\circ\text{C} (378,05 \text{ K})$	$C_b(0) = 1,09 \text{ mol/L}$
$F/V_r = 14,19 \text{ h}^{-1}$	$T_r(0) = 114,2 \text{ }^\circ\text{C} (387,35 \text{ K})$
$Q_j = - 1113,5 \text{ kJ/h}$	$T_j(0) = 112,9 \text{ }^\circ\text{C} (386,05 \text{ K})$

Fonte: Kulikov e Kulikova, 2014, p. 760.

Neste estudo de caso, foi examinado o desempenho do controlador preditivo associado ao filtro de partículas considerando restrições nos estados, por meio do algoritmo CPF-MPC. Desse modo, foi avaliada a capacidade da ferramenta em estimar as concentrações de A e B, além de controlar a concentração de B medindo somente as temperaturas T_r e T_j . Os vetores de estados e entrada, juntamente com o das medidas, são dados pelas Equações (85) e (87) (KULIKOV; KULIKOVA, 2014).

$$\mathbf{x}(k) = [C_a(k), C_b(k), T_r(k), T_j(k)]^T \quad (85)$$

$$\mathbf{u}(k) = [C_{af}(k), T_f(k), F/V_r(k), Q_j(k)]^T \quad (86)$$

$$\mathbf{y}(k) = [T_r(k), T_j(k)]^T + \mathbf{v}(k) \quad (87)$$

Para avaliar seu desempenho, o controlador foi arranjado considerando um problema de controle com duas entradas. Sendo assim, as variáveis manipuladas são a razão de alimentação F/V_r e a taxa de remoção de calor Q_j . Apenas a concentração do reagente B é considerada a variável controlada (CHEN; KREMLING; ALLGOWER, 1995). O processo está sujeito às restrições, conforme as Equações (88) - (92).

$$0,8\text{mol} / L \leq C_b \leq 1,09\text{mol} / L \quad (88)$$

$$100^\circ C \leq T_f \leq 115^\circ C \quad (89)$$

$$3h^{-1} \leq F/V_r \leq 35h^{-1} \quad (90)$$

$$-9000\text{kJ} / h \leq Q_j \leq 0\text{kJ} / h \quad (91)$$

$$4,5\text{mol} / L \leq C_{af} \leq 5,7\text{mol} / L \quad (92)$$

Devido às instabilidades do processo, o objetivo deste trabalho foi controlar a concentração do reagente B no reator em cerca de 3% do valor desejado. Os valores medidos \mathbf{y}_m foram obtidos a partir dos resultados do modelo (valores exatos, \mathbf{y}_{exato}). Desse modo, aos “valores exatos” foram adicionados ruídos gaussianos, aditivos, com média zero e desvio padrão de 1% dos valores exatos, como pode ser visto na Equação (93).

$$\mathbf{y}_m = \mathbf{y}_{exato} + N(0,01 \cdot \mathbf{y}_{exato}) \quad (93)$$

o desempenho do controlador foi avaliado por meio de um teste servo com degrau tipo rampa no *setpoint* da concentração do reagente B. Também foram realizados testes reguladores com perturbações em duas das entradas do processo (T_f e C_{af}).

O comportamento das concentrações de A e B, da temperatura T_r e das variáveis manipuladas foram avaliados na simulação desse estudo de caso. Além disso, foi verificado também se as restrições impostas às entradas e aos estados estimados para o sistema foram respeitadas.

5.4 Estudo de Caso 3: Circuito de fragmentação e classificação do minério de ferro

Este tópico visa à apresentação de um modelo matemático para o circuito de moagem do minério de ferro, dando melhor concepção para simulação e controle (COETZEE, 2009).

No circuito de moagem do minério de ferro os três módulos principais são o moinho, o reservatório e o hidrociclone como mostram a Figura 14. O processo recebe quatro correntes: minério extraído, água, esferas de aço e a saída inferior do hidrociclone. O minério é moído no interior do moinho e juntamente com a água forma uma suspensão que promove a moagem e faz o material fluir através do moinho. Nesta etapa uma grade limitação é o tamanho das partículas da lama descarregada. O reservatório recebe essa suspensão e ajusta sua densidade (pela adição de mais água) antes de bombeá-la até a etapa de classificação. O objetivo do hidrociclone é separar o material em especificado e fora da especificação (MATTHEWS; CRAIG, 2013).

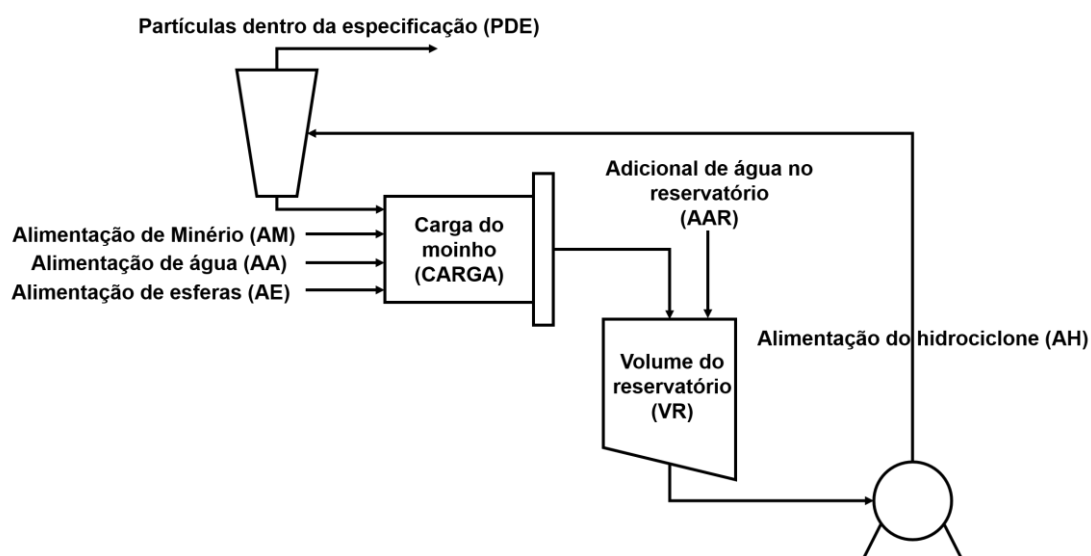


Figura 14 - Esquema do circuito de moagem. Fonte: Olivier, Haung e Craig (2012), modificado pelo autor.

As variáveis do circuito descritas no esquema são mostradas na Tabela 5.

Tabela 5 - Condições operacionais e restrições das variáveis do circuito.

	Min	Max	Op.	Δ	Descrição
MV					
AA	0	20	4,64	2	Alimentação de água no moinho [m^3/h]
AM	0	100	57,54	1	Alimentação de minério no moinho [t/h]
AE	0	10	5,9	0,5	Alimentação esferas no moinho [t/h]
a_{speed}	0,6	0,85	0,12	0,01	Fração da velocidade crítica do moinho [%]
AAR	0	400	201,7	-	Alimentação de água no reservatório [m^3/h]
AH	100	500	456,8	5	Taxa de alimentação do hidrociclone [m^3/h]
CV					
CARGA	0,2	0,5	0,3398	-	Fração da carga do moinho
VR	2	20	5,9893	-	Volume do reservatório [m^3]
PDE	0,5	0,85	0,75	-	Tamanho da partícula do produto [$<75\mu m$]
THP	0	74	17,981	-	Volume de sólidos [m^3/h]
P_M	0	2000	1182,5	-	Potência do motor do moinho [kW]
DAH	1	2	1,6119	-	Densidade de alimentação do hidrociclone, kg/m^3

Fonte: Naidoo, 2014, p. 9.

Um modelo não linear com complexidade reduzida foi proposto por Le Roux *et al.* (2013) para representar o processo descrito acima. O modelo utiliza seis estados (água, rocha, sólidos, finos, grosseiros e esferas de aço). Rochas são considerados os minérios que são grandes demais para passar pela grade de descarga do moinho, enquanto os sólidos são aqueles capazes de passar por essa barreira. A soma dos finos e grosseiros fornece o total de sólidos presentes na lama. Os finos são parte do minério que possuem tamanho menor que o da especificação do produto e os grosseiros representam a parte maior que o valor de especificação. Esferas de aço são adicionadas ao moinho e auxiliam na moagem e a água é adicionada para criar a suspensão e facilitar o transporte de minério pelo circuito (LE ROUX; PADHI; CRAIG, 2014).

Quatro módulos compõem o modelo: alimentação, moinho, o reservatório e o hidrociclone. Para as equações V denota a vazão em m^3/h , enquanto X denota os estados do modelo com volumes em m^3 . A Tabela 6 fornece uma descrição dos subscritos para V e X . O primeiro indica o módulo do circuito, o segundo faz referência ao estado considerado e o último representa se a vazão é uma entrada ou saída (LE ROUX; PADHI; CRAIG, 2014).

Tabela 6 - Descrição dos subscritos do modelo.

Subscrito	Descrição
$X_{\Delta-}$	a – água; g – grosseiros; f – finos; r – rochas; e – esferas; t - total
$X_{-\Delta}$	a – alimentação; m – moinho; r – reservatório; h - hidrociclone
$V_{\Delta--}$	e – entrada; s – saída; u – <i>underflow</i>
$V_{-\Delta-}$	a – água; g – grosseiros; f – finos; r – rochas; e – esferas; t - total
$V_{--\Delta}$	m – moinho; r – reservatório; h - hidrociclone

Fonte: Naidoo, 2014, p. 10.

O modelo da alimentação é a parte mais simples do modelo que retém a alimentação total do moinho e divide-a em várias correntes para os respectivos estados que são distribuídos e utilizados por todo o circuito. De acordo com Olivier (2011) este módulo pode ser substituído por modelos de alimentadores reais, como por exemplo, alimentadores vibratórios. As taxas de fluxo volumétrico que saem do alimentador são definidas pelas Equações (94) - (98).

$$V_{ssa} \triangleq AA \quad (94)$$

$$V_{ssa} \triangleq \frac{AM}{D_s} (1 - \alpha_r) \quad (95)$$

$$V_{sfa} \triangleq \frac{AM}{D_s} \alpha_f \quad (96)$$

$$V_{sra} \triangleq \frac{AM}{D_s} \alpha_r \quad (97)$$

$$V_{sea} \triangleq \frac{AE}{D_b} \quad (98)$$

O modelo pode ser descrito em um conjunto de equações de espaço estado como visto nas Equações (99) - (106).

$$\frac{dX_{am}}{dt} \triangleq V_{eam} + V_{uah} - V_{sam} \quad (99)$$

$$\frac{dX_{sm}}{dt} \triangleq V_{esm} + V_{ush} - V_{ssm} + CR \quad (100)$$

$$\frac{dX_{fm}}{dt} \triangleq V_{efm} + V_{ufh} - V_{sfm} + PF \quad (101)$$

$$\frac{dX_{rm}}{dt} \triangleq V_{erm} - CR \quad (102)$$

$$\frac{dX_{em}}{dt} \triangleq V_{eem} - CE \quad (103)$$

$$\frac{dX_{ar}}{dt} \triangleq V_{sam} - V_{sar} + AAR \quad (104)$$

$$\frac{dX_{sr}}{dt} \triangleq V_{ssm} - V_{ssr} \quad (105)$$

$$\frac{dX_{fr}}{dt} \triangleq V_{sfm} - V_{sfr} \quad (106)$$

Em que X_{am} , X_{sm} , X_{fm} , X_{rm} e X_{em} são o volume da água, sólidos, finos, rochas e esferas no interior do moinho, respectivamente. X_{ar} , X_{sr} e X_{fr} são o volume de água, sólidos e finos no reservatório, respectivamente, e V_{uah} , V_{ush} e V_{ufh} são respectivamente o *underflow* de água, sólidos e finos que saem do hidrociclone. Os parâmetros e a nomenclatura do modelo podem ser visualizados na Tabela 7.

Tabela 7 - Valores dos parâmetros para o modelo do circuito.

	Valor	Descrição
Parâmetros do moinho		
α_f	0,055	Fração de finos no minério
α_r	0,465	Fração de rochas no minério
Φ_f	29,57	Potência necessária por tonelada de finos produzidos [kWh/ton]
Φ_r	6,03	Fator de abrasão da rocha [kWh/t]
Φ_b	90	Fator de abrasão das esferas [kWh/t]
ε_{sv}	0,6	Fração máxima de sólidos por volume de lama (a fluxo de lama zero)
δ_{pv}	0,5	Parâmetro do poder de mudança para o volume de moinho
V_{pmax}	0,34	Fração de volume do moinho para a máxima potência
V_{moinho}	59,1	Volume do moinho [m ³]
XP	0	Termo cruzado para a força máxima
δ_{ps}	0,5	Parâmetro do poder de mudança para a fração de sólidos
Φ_{p_max}	0,57	Fator reológico para a potência máxima do moinho
α_p	1	Redução da potência fracionada por redução fracionada da velocidade máxima do moinho
Vv	84	Fluxo volumétrico pela força motriz “volume de fluxo” [h ⁻¹]
$\alpha\Phi_f$	0,01	Razão entre os finos produzidos e o volume de carga do moinho
P_{max}	1662	Potência máxima do moinho [kW]
Parâmetros do hidrociclone		
α_{su}	0,87	Fração de sólidos na saída do hidrociclone
ε_c	128,8	Fração de grosseiros na saída do hidrociclone [m ³ /h]
	5	
C_1	0,6	Constante
C_2	0,7	Constante
C_3	4	Constante
C_4	4	Constante
D_s	3,2	Densidade do minério [t/m ³]
D_b	7,85	Densidade das esferas [t/m ³]

Fonte: Le Roux *et al.*, 2013, p. 129.

As entradas de água, rochas, esferas de aço, sólidos e finos do moinho são descritas em termos das vazões volumétricas de alimentação do moinho como exemplificado pela Equação (107).

$$[V_{saa}, V_{ssa}, V_{sfa}, V_{sra}, V_{sba}]^T = [V_{eam}, V_{asm}, V_{afm}, V_{arm}, V_{aem}]^T \quad (107)$$

As saídas do modelo são: a fração da carga total do moinho (CARGA), o volume do reservatório VR, a estimativa do tamanho das partículas no *overflow* do hidrociclone dentro da especificação (PDE), o *product throughput* (THP), que é definido como o

volume de sólidos no *overflow* do ciclone, a potência do moinho (P_m) e a densidade da lama que entra no hidrociclone (DAH). Essas variáveis são definidas conforme as Equações (108) - (113).

$$CARGA = (X_{am} + X_{sm} + X_{rm} + X_{bm}) / v_{moinho} \quad (108)$$

$$VR = X_{sr} + X_{ar} \quad (109)$$

$$PDE = \frac{V_{sfh}}{V_{ssh}} \quad (110)$$

$$THP = V_{cso} \quad (111)$$

$$P_m = P_{\max} \{1 - \delta_{p_v} Z_x^2 - 2\chi_P \delta_{p_v} \delta_{p_x} Z_x Z_r - \delta_{p_v} Z_r^2\} (\alpha_{speed})^{\alpha_p} \quad (112)$$

$$DAH = \frac{X_{mr} + D_s X_{sr}}{X_{mr} + X_{sr}} \quad (113)$$

Nessas Equações, V_{sfh} e V_{ssh} representam o volume de finos e sólidos que saem no *overflow* do hidrociclone, respectivamente. As equações intermediárias necessárias para o modelo relacionadas ao módulo do moinho são definidas por meio das Equações (114) - (122).

$$\varphi \triangleq \max \left[0, \left(1 - \left(\frac{1}{\varepsilon_{sv}} - 1 \right) \frac{X_{sm}}{X_{am}} \right)^{0.5} \right] \quad (114)$$

$$Z_x \triangleq \frac{CARGA}{v_{P\max}} - 1 \quad (115)$$

$$Z_r \triangleq \frac{\varphi}{\varphi_{P\max}} - 1 \quad (116)$$

$$CR = \frac{1}{D_s \varphi_r} P_{mill} \varphi \left(\frac{X_{rm}}{X_{rm} + X_{sm}} \right) \quad (117)$$

$$PF = \frac{P_m}{D_s \phi_f \left[1 + \alpha_{\phi_f} (CARGA - v_{P\max}) \right]} \quad (118)$$

$$CE = \frac{1}{D_b \phi_b} P_m \varphi \left(\frac{X_{rm}}{X_{rm} + X_{sm}} \right) \quad (119)$$

$$V_{sam} \triangleq V_V \varphi X_{am} \left(\frac{X_{am}}{X_{am} + X_{sm}} \right) \quad (120)$$

$$V_{ssm} \triangleq V_V \varphi X_{am} \left(\frac{X_{sm}}{X_{am} + X_{sm}} \right) \quad (121)$$

$$V_{sfm} \triangleq V_V \varphi X_{am} \left(\frac{X_{fm}}{X_{am} + X_{sm}} \right) \quad (122)$$

φ é fator de reologia, que está relacionado com a fluidez da lama dentro do moinho, Z_x o efeito da carga do moinho sobre o consumo de energia, Z_r o efeito da reologia da suspensão sobre o consumo de energia. CR , CE e PF representam respectivamente, o consumo de rochas, o consumo de esferas de aço e a produção de finos (COETZEE, 2009).

As entradas de água, sólidos e finos do reservatório são descritas em termos das vazões volumétricas de saída do moinho como apresentado pela Equação (123).

$$[V_{ear}, V_{esr}, V_{efr}]^T = [V_{sam}, V_{ssm}, V_{sfm}]^T \quad (123)$$

As equações intermediárias necessárias para o modelo relacionadas ao módulo do reservatório são aquelas que dizem respeito às saídas do módulo e são descritas da conforme mostram as Equações (124) - (126).

$$V_{sar} = AAR \left(\frac{X_{ar}}{X_{ar} + X_{sr}} \right) \quad (124)$$

$$V_{ssr} = AAR \left(\frac{X_{sr}}{X_{ar} + X_{sr}} \right) \quad (125)$$

$$V_{sfr} = AAR \left(\frac{X_{fr}}{X_{ar} + X_{sr}} \right) \quad (126)$$

As entradas de água, grosseiros, sólidos e finos do hidrociclone são descritas em termos das vazões volumétricas de saída do misturador como exemplificado na Equação (127).

$$[V_{eah}, V_{egh}, V_{esh}, V_{efh}]^T = [V_{sar}, V_{ssr} - V_{sfr}, V_{ssr}, V_{sfr}]^T \quad (127)$$

O módulo do hidrociclone é descrito adicionalmente pelas Equações intermediárias, conforme mostram as Equações (128) - (133).

$$F_i = \frac{V_{esh}}{AAR} \quad (128)$$

$$P_i = \frac{V_{efh}}{V_{esh}} \quad (129)$$

$$V_{ugh} = V_{egh} \left(1 - C_1 e^{\left(\frac{-AAR}{\varepsilon_c} \right)} \right) \left(1 - \left(\frac{F_i}{C_2} \right)^{C_3} \right) (1 - P_i^{C_4}) \quad (130)$$

$$F_u = 0.6 - (0.6 - F_i) e^{(-V_{ugh}/(\alpha_{su}\varepsilon_c))} \quad (131)$$

$$V_{uah} = \frac{V_{eah}(V_{ugh} - F_u V_{ugh})}{(F_u V_{eah} + F_u V_{efh} - V_{efh})} \quad (132)$$

$$V_{ufh} = \frac{V_{efh}(V_{ugh} - F_u V_{ugh})}{(F_u V_{eah} + F_u V_{efh} - V_{efh})} \quad (133)$$

Nestas equações, F_i é a fração de sólidos na vazão de entrada do hidrociclone AAR e depende da taxa volumétrica de sólidos que entra no hidrociclone V_{esh} . P_i é a fração de finos no sólidos de alimentação do classificador, V_{efh} é a taxa de finos presente na alimentação e F_u é a fração de sólidos no *underflow* do hidrociclone. O fluxo de minério bruto no *underflow* V_{ugh} é proporcional à quantidade presente no ciclone V_{egh} e para ser calculado depende de C_1 (uma constante que descende o equipamento quando a força centrífuga é pequena), de ε_c (que define a velocidade com que o fluxo de materiais maiores decai quando a força centrífuga aumenta), de C_2 (constante que normaliza os sólidos na fração de alimentação), de C_3 (que determina a nitidez da curva) e também de C_4 (define a velocidade com que a função atinge o valor nulo). Os valores das condições dos estados iniciais são mostrados na Tabela 8 e foram obtidos após utilizar os dados de Le Roux *et al.* (2013), simulando o modelo proposto até atingir o estado estacionário, ao passo que essa condição estável foi utilizada como inicial para as simulações neste trabalho, garantindo estabilidade do processo.

Tabela 8 - Condições operacionais do circuito.

Estado	Min	Max	Op	Δ	Descrição
X_{am}	0	50	5,22	-	Volume de água no moinho [m ³]
X_{sm}	0	50	5,18	-	Volume de sólidos no moinho [m ³]
X_{fm}	0	50	0,88	-	Volume de finos no moinho [m ³]
X_{rm}	0	50	1,59	-	Volume de rochas no moinho [m ³]
X_{em}	0	50	8,09	-	Volume de esferas no moinho [m ³]
X_{ar}	0	50	4,32	-	Volume de água no misturador [m ³]
X_{sr}	0	50	1,67	-	Volume de sólidos no misturador [m ³]
X_{fr}	0	50	0,28	-	Volume de finos no misturador [m ³]

Fonte: Fonte: Naidoo, 2014, p.9.

Os principais objetivos de controle deste processo são: a manutenção da estabilidade e a obtenção de uma boa qualidade do produto (relacionada ao produto das partículas em especificação, PDE). Nesse sentido, é necessário ressaltar que o circuito de fragmentação e classificação de minério de ferro possui, ao mesmo tempo, circuitos dinâmicos rápidos e lentos. Por exemplo, a constante de tempo da malha AM/PDE é cerca de 30 min, enquanto para a malha AH/PDE é na casa de 2 min (LE ROUX *et al.*, 2016). Dessa forma, o esquema de controle para esse processo pode ser claramente projetado com duas camadas de controle de acordo com a escala de tempo (SKOGESTAD, 2000), de modo que a camada reguladora deve ser usada para garantir a estabilidade do processo, utilizando controladores de ação rápida com baixo custo computacional (como controladores PID); e para a camada supervisória, a presente dissertação propôs a implementação da abordagem do PF-MPC para a variável de garantia de qualidade do produto.

Um controlador PI é escolhido para suprir à dinâmica mais rápida do reservatório, controlando VR. Além disso, um controlador PI também é utilizado para regular a CARGA do moinho. Dessa forma, o PF-MPC determina as trajetórias desejadas das variáveis de qualidade do processo (PDE) em um tempo maior.

O esquema de controle para o PF-MPC é apresentado conforme a Figura 15.

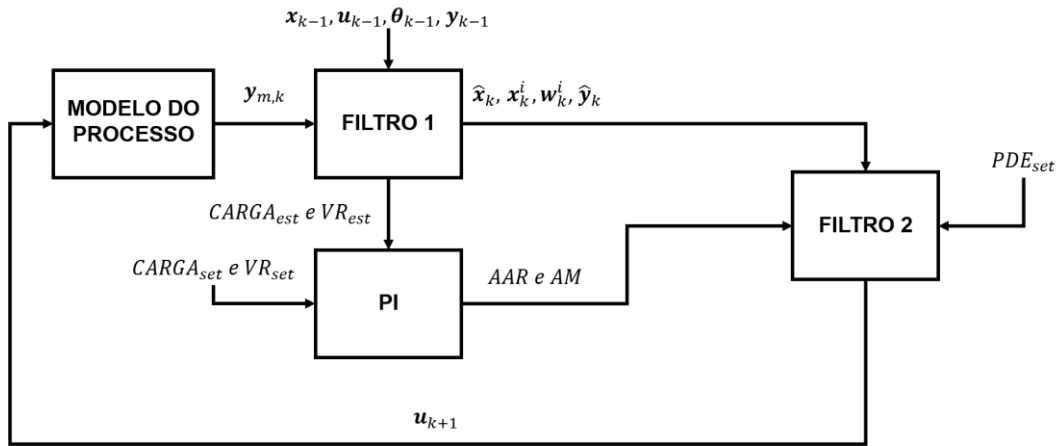


Figura 15 - Esquema de controle com o controlador PF-MPC para o problema do circuito.
Fonte: Próprio autor.

Como mostrado na Figura 15, o PF-MPC trabalha como controle supervisor e utiliza a variável manipulada AH para controlar a variável PDE. O controlador PI controla VR via AAR e CARGA via AM, garantindo a estabilidade do processo. Como VR não tem impacto sobre o estado estacionário do sistema, seu *setpoint* precisa apenas garantir que esteja dentro do limite restringido pelo processo.

Os estados, as variáveis manipuladas e as variáveis controladas utilizadas pelo para o esquema de controle que utiliza o PF-MPC no controle de PDE são apresentadas de acordo com as Equações (134) - (136).

$$\mathbf{x}_c = [X_{am}, X_{sm}, X_{fm}, X_{fn}, X_{em}, X_{ar}, X_{sr}, X_{fr}]^T \quad (134)$$

$$\mathbf{u}_c = [AA, AM, AE, \alpha_{speed}, AH]^T \quad (135)$$

$$\mathbf{y}_c = [CARGA, VR, PDE]^T \quad (136)$$

Os tempos de amostragem das camadas regulatória e supervisor são considerados foram, respectivamente, 1 e 5 minutos, consistentes com o tempo necessário para se obter medidas de qualidade em um processo real. Assim, a camada superior é ativada a cada cinco vezes que a inferior é realizada.

Para as incertezas das partículas assumiu-se que as estimativas iniciais dos estados são selecionadas aleatoriamente e possuem densidade a priori com desvio padrão de 0.02. A função de probabilidade é assumida como sendo normal, com desvio padrão de 0.1. Considerou-se uma região de credibilidade de 99%, calculada para cada tempo de amostragem, avaliando se o filtro foi capaz de reduzir os efeitos das

incertezas. Para avaliar o desempenho da estrutura de controle foi utilizado o erro médio quadrático (RMS) e a soma do erro absoluto (AES).

Para a geração das medidas simuladas, foram acrescentados ruídos gaussianos, aditivos, com média zero e desvio padrão de acordo com o valor inicial gerado a partir dos estados iniciais, conforme listados na Tabela 9. Não são adicionados ruídos aos estados, pois seria necessário diferenciar entre o efeito cumulativo do ruído de estado e a medição ao avaliar o desempenho do controlador. Sendo assim, o ruído adicionado somente às variáveis controladas é suficiente para explicar o modelo de incerteza (LE ROUX *et al.*, 2016).

Tabela 9 - Ruídos de medição da planta em percentual dos valores nominais das variáveis.

Variável	Σ	Variável	Σ
CARGA	1%	VR	0,5%
PDE	1%	P_M	2%
THP	1%	DAH	1,5%

Fonte: Le Roux *et al.*, 2016, p. 45.

Com o intuito de avaliar o desempenho do PF-MPC para o controle do PDE, um esquema de controle similar será proposto, porém, nesse novo algoritmo, um controlador clássico PI será utilizado para o controle do PDE, enquanto as demais variáveis (CARGA e VR) serão controladas da mesma forma. Um esquema dessa estratégia de comparação pode ser visualizado por meio da Figura 16. Além disso, para que fosse possível uma avaliação justa, as restrições sobre os estados estimados não foram consideradas (algoritmo PF-MPC) e as sequências de ruído foram mantidas as mesmas em ambas as simulações.

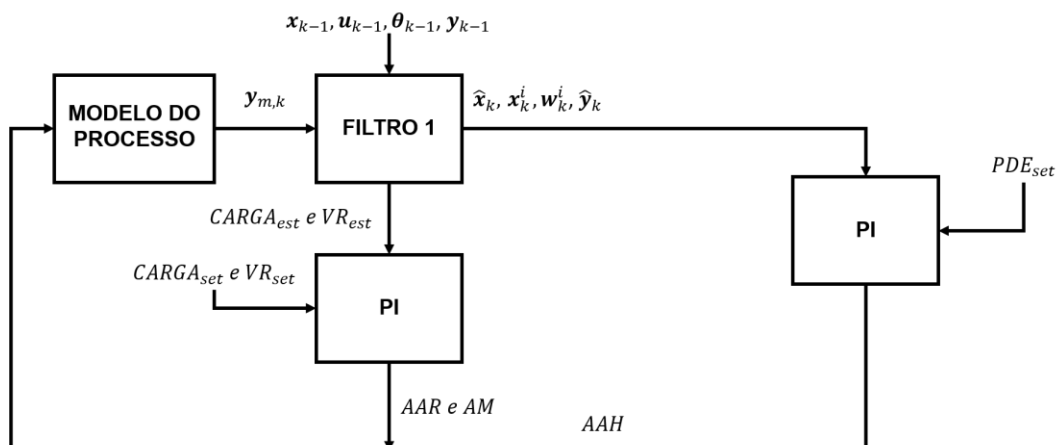


Figura 16 - Esquema de controle com o controlador PI para o controle do circuito. Fonte: Próprio autor.

Os estados, as variáveis manipuladas e as variáveis controladas utilizadas pelo esquema de controle no qual o controlador PID foi utilizado para a camada supervisória são mostradas por meio das Equações (137) - (139).

$$\mathbf{x}_c = [X_{am}, X_{sm}, X_{fm}, X_{m}, X_{em}, X_{ar}, X_{sr}, X_{fr}]^T \quad (137)$$

$$\mathbf{u}_c = [AM, AH, AH]^T \quad (138)$$

$$\mathbf{y}_c = [CARGA, VR, PDE]^T \quad (139)$$

5.4.1 Perturbação no setpoint: Teste servo

Para avaliar a eficácia do controlador proposto ao ser comparado com o controlador PI foram realizados dois testes servos, na variável controlada PDE e também na variável controlada VR, mantendo o *setpoint* da CARGA constante. No tempo igual a 90min ou 1h30 de simulação o *setpoint* de VR decairá 85% e no tempo igual a 240min ou 4h de simulação o *setpoint* de PDE aumentará em 1%. A fim de se realizar uma comparação justa não foram consideradas as restrições na análise do desempenho dos controladores.

5.4.2 Perturbação nos parâmetros do processo: Teste regulador

De acordo com Le Roux *et al.* (2016), todas as plantas industriais precisam funcionar em meio a distúrbios no decorrer do processo, sendo os mais importantes os relacionados à distribuição do minério de alimentação e à dureza do minério. Desse modo, a fim de avaliar o desempenho do controlador, são aplicados distúrbios nesses dois parâmetros importantes do processo. Os seguintes distúrbios são aplicados:

1. Uma variação na distribuição do tamanho da alimentação foi simulada a partir de um desvio uniforme $U(-\Delta, \Delta)$ na variável, entre o intervalo de tempo de 120 a 180min.

2. Um desvio nos parâmetros relacionados à dureza do minério foi simulado da mesma forma entre o intervalo de tempo de 240 a 300min de operação.

O Δ representa o desvio do valor nominal que o parâmetro pode atingir no intervalo em que é perturbado. O desvio como percentual do valor nominal é apresentado pela Tabela 10.

Tabela 10 - Variação dos parâmetros em relação ao seu valor nominal.

Parâmetro	Δ	Parâmetro	Δ
α_f	30%	ϕ_f	20%
α_r	30%	ϕ_r	20%

Fonte: Le Roux *et al.*, 2016, p.45.

6 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos os resultados obtidos na aplicação da metodologia de controle preditivo associado ao filtro de partículas desenvolvida neste trabalho para os três estudos de caso apresentados no Capítulo 5. Foi realizado um planejamento de testes e avaliação de parâmetros no filtro de partículas, que possibilitaram avaliar a influência dessas variáveis no controle de cada sistema considerado com suas particularidades.

6.1 Resultados: Estudo de caso 1

Os resultados para o reator CSTR foram divididos conforme as análises propostas e listadas pela metodologia da Dissertação.

6.1.1 *Avaliação dos parâmetros do CPF-MPC*

Repetindo em 60 vezes a simulação para as combinações com os respectivos números de partículas (10 e 100) e para cada valor de desvio padrão (0,1, 0,5 e 5) é possível realizar uma comparação estatística entre os dados. A Tabela 11 apresenta a análise estatística, fornecendo a média e a variância de RMS e AES para cada simulação realizada.

Tabela 11 - Conjunto de dados para as análises estatísticas para as simulações.

N_{part}	σ	$\bar{x}(RMS)$	$S^2(RMS)$	$\bar{x}(AES)$	$S^2(AES)$	N	G.L
10	0,1	0,0314	$6,9183 \times 10^{-6}$	6,8411	0,0883	10	9
	0,5	0,0252	$1,4960 \times 10^{-6}$	10,5757	0,2399	10	9
	5	0,0244	$3,1627 \times 10^{-6}$	11,2670	0,1302	10	9
100	0,1	0,0275	$1,2916 \times 10^{-6}$	6,0785	0,0335	10	9
	0,5	0,0226	$3,3218 \times 10^{-6}$	9,2102	0,1498	10	9
	5	0,0213	$1,3204 \times 10^{-6}$	10,6421	0,1118	10	9

Em que N_{part} é o número de partículas, σ é o desvio padrão para a função de verossimilhança do segundo filtro, \bar{x} a média, S^2 a variância, N o número de observações e G.L o grau de liberdade do conjunto.

A avaliação dos critérios RMS e AES se deu em duas frentes distintas: na primeira, foi fixado o número de partículas e variou-se o desvio padrão do segundo filtro; na segunda, o desvio padrão foi mantido o mesmo para dois diferentes números de partículas.

6.1.1.1 Efeito do desvio padrão

Na implementação do algoritmo CPF-MPC é muito importante uma avaliação do desvio padrão, pois, influencia o cálculo dos pesos no segundo filtro, que atua diretamente no cômputo da ação de controle ótima.

Assim, ao se fixar o número de partículas é possível avaliar se a mudança do valor do desvio padrão “ σ ” para o segundo filtro afeta de maneira significativa a estatística do RMS e do AES.

Ao considerar 10 e 100 partículas e valores do desvio padrão do segundo filtro de 0,1 e 5 (valores extremos), podem-se observar os seguintes intervalos para a média e variância do critério RMS, conforme a Tabela 12.

Tabela 12 - Análise estatística para o RMS, fixando o número de partículas.

N_{part}	σ	Intervalo t Student para a média	Intervalo chi-quadrado para a variância
10	0,1	0,0295<0,0314<0,0332	$3,2732 \times 10^{-6} < 6,9183 \times 10^{-6} < 2,3058 \times 10^{-5}$
	5	0,0231<0,0244<0,0256	$1,4963 \times 10^{-6} < 3,1627 \times 10^{-6} < 1,0541 \times 10^{-5}$
100	0,1	0,0266<0,0275<0,0283	$6,1106 \times 10^{-7} < 1,2916 \times 10^{-6} < 4,3046 \times 10^{-6}$
	5	0,0205<0,0213<0,0222	$6,2473 \times 10^{-7} < 1,3204 \times 10^{-6} < 4,4008 \times 10^{-6}$

Comparando os intervalos de confiança para a média, observa-se que ao nível de confiança de 95% de confiança não há interseção dos intervalos, de maneira que é possível dizer que as médias, quando se considera dois desvios padrão distintos em um mesmo número de partículas, são diferentes. Por outro lado, uma comparação para a variância permite dizer que há interseção na região entre ($3,2732 \times 10^{-6}$ e $1,0541 \times 10^{-5}$), de modo que não é possível dizer que as variâncias são distintas. Sendo assim, por esses critérios pode-se considerar que as médias não são estatisticamente equivalentes.

De maneira similar, ao aplicar o teste F para 95% de confiança, obtém-se um intervalo de $0,2484 < F < 4,026$, e o valor de F obtido corresponde a 2,1875, satisfazendo o intervalo. Logo, confirma a conclusão obtida no intervalo do teste chi-quadrado, que afirma que é provável que as variâncias reais para os dois níveis de desvio padrão sejam iguais. Sendo assim, pode-se afirmar com 95% de confiança que os conjuntos amostrais não possuem a mesma média, mas possuem a mesma variância.

Com base nessa análise, é possível observar o mesmo comportamento quando se utiliza 100 partículas e busca avaliar a influência de diferentes números de desvio padrão para o segundo filtro. Por semelhante modo, uma simulação com 100 partículas, também é possível obter a mesma discussão.

Sendo assim, pode-se afirmar com 95% de confiança que os conjuntos amostrais nos quais são mantidos o mesmo número de partículas e varia-se o desvio padrão do segundo filtro, os dados não possuem a mesma média, mas possuem a mesma variância, no que diz respeito ao RMS.

Esses resultados permitem concluir que um aumento no valor do desvio padrão do segundo filtro ocasiona uma melhora na estimativa, gerando menores valores de RMS.

Uma análise semelhante pode ser realizada para o critério AES. A Tabela 13 apresenta os valores dos intervalos para esse critério.

Tabela 13 - Análise estatística para o AES, fixando o número de partículas.

N_{part}	σ	Intervalo t Student para a média	Intervalo chi-quadrado para a variância
10	0,1	6,6285<6,8411<7,0536	0,0418<0,0883<0,2942
	5	11,0088<11,267<11,5251	0,0616<0,1302<0,4339
100	0,1	5,9474<6,0785<6,2095	0,0159<0,0335<0,1118
	5	10,4029<10,6421<10,8813	0,0529<0,1118<0,3752

Para 10 partículas, ao comparar o intervalo da média para valores de desvio padrão de 0,1 e 5 é possível notar que não há interseção entre os valores e as médias são diferentes para os grupos. Quando a avaliação é acerca do intervalo para a variância nota-se que, há interseção entre o intervalo (0,0616 e 0,2942), de maneira que não é possível dizer que as variâncias são diferentes. Quando se utiliza do teste F o intervalo obtido para o mesmo foi de $0,2484 < F < 4,026$ e o valor calculado com base nos dados dos dois grupos foi de 0,6779, satisfazendo a desigualdade anterior. Logo, é provável que as variâncias reais dos dois grupos amostrais sejam iguais.

Por semelhante modo, ao avaliar o mesmo caso, porém com 100 partículas, nota-se também que não há interseção entre os intervalos para a média, sendo essa distinta entre os grupos. Uma avaliação acerca do intervalo para a variância permite dizer que há interseção entre o intervalo 0,0529 e 0,1118, de modo que não é possível dizer que as variâncias são diferentes. Da mesma forma, ao utilizar o teste F, o intervalo obtido foi de $0,2484 < F < 4,026$ e o valor calculado para dados foi de 0,3000, valor que satisfaz a desigualdade. Desse modo, também é provável que as variâncias reais dos dois grupos sejam iguais.

Com base nas avaliações estatísticas acima, pode-se dizer que uma diminuição no valor do desvio padrão do segundo filtro ocasiona melhora no desempenho do controle, gerando menores valores de AES.

6.1.1.2 Efeito do número de partículas

Outra comparação pode ser realizada ao se fixar um valor de desvio padrão (em 0,1 e 5) e variar o número de partículas (em 10 e 100), permitindo avaliar estatisticamente os valores de RMS, conforme detalhado na Tabela 14.

Tabela 14 - Análise estatística para o RMS, fixando o desvio padrão do segundo filtro.

σ	N_{part}	Intervalo t Student para a média	Intervalo chi-quadrado para a variância
0,1	10	0,0295<0,0314<0,0332	$3,2732 \times 10^{-6} < 6,9183 \times 10^{-6} < 2,3058 \times 10^{-5}$
	100	0,0266<0,0275<0,0283	$6,1106 \times 10^{-7} < 1,2916 \times 10^{-6} < 4,3046 \times 10^{-6}$
5	10	0,0231<0,0244<0,0256	$1,4963 \times 10^{-6} < 3,1627 \times 10^{-6} < 1,0541 \times 10^{-5}$
	100	0,0205<0,0213<0,0222	$6,2473 \times 10^{-7} < 1,3204 \times 10^{-6} < 4,4008 \times 10^{-6}$

Semelhante discussão feita acima pode ser realizada ao comparar para um mesmo desvio padrão e diferentes número de partículas. Quando o desvio padrão para o segundo filtro é de 0,1, observe que para uma comparação entre 10 e 100 partículas não há interseção entre os valores de RMS, o que torna possível afirmar que as médias desses valores são diferentes. Ao avaliar os intervalos para a variância, nota-se que há interseção (entre $3,2732 \times 10^{-6}$ e $4,3046 \times 10^{-6}$). Dessa forma, não é possível dizer que as variâncias são diferentes. O valor do F calculado foi de 5,3566 para um intervalo de $0,2584 < F < 4,026$, o que permite dizer que provavelmente as variâncias reais dos dois grupos não são iguais.

Segundo Schwaab e Pinto (2007), é normal obter conclusões distintas acerca dos intervalos de confiança e para o teste F. No entanto, os autores afirmam que o teste F tem maior capacidade em detectar diferenças na variabilidade dos dados do que os intervalos de confiança obtidos pela distribuição chi-quadrado. Portanto, pode-se afirmar com 95% de confiança que, além de possuírem médias distintas, os conjuntos também possuem variâncias distintas e se diferem estatisticamente.

Para o desvio padrão de 5 também não é possível observar interseção entre os intervalos da média, sendo assim, pode-se afirmar que as médias desses valores são diferentes. Quando o intervalo para a variância é avaliado, percebe-se interseção entre os valores $1,4963 \times 10^{-6}$ e $4,4008 \times 10^{-6}$, de modo que não é possível afirmar que as variâncias são diferentes. A avaliação para a variabilidade das amostras realizada pelo teste F informa que para esses dados, o valor de F

calculado foi de 2,3952 para um intervalo de $0,2584 < F < 4,026$, permite dizer que provavelmente as variâncias reais dos dois grupos são equivalentes.

Em virtude da discussão realizada acima, pode-se concluir que um aumento no número de partículas ocasiona uma melhora no valor do RMS, ou seja, uma diminuição no valor do erro da estimativa.

Quando a comparação para o critério AES é realizada em um cenário no qual foram fixados os valores de desvio padrão para diferentes números de partículas, observam-se os resultados conforme descritos pela Tabela 15.

Tabela 15 - Análise estatística para o AES, fixando o desvio padrão do segundo filtro.

σ	N_{part}	Intervalo t Student para a média	Intervalo chi-quadrado para a variância
0,1	10	6,6285<6,8411<7,0536	0,0418<0,0883<0,2942
	100	5,9474<6,0785<6,2095	0,0159<0,0335<0,1118
5	10	11,0088<11,2670<11,5251	0,0616<0,1302<0,4339
	100	10,4029<10,6421<10,8813	0,0529<0,1118<0,3725

Para um desvio padrão de 0,1 nota-se que não ocorre interseção entre os intervalos da média, de maneira que é possível dizer que as médias são diferentes. De maneira análoga, ao analisar os intervalos para a variância nota-se uma interseção entre 0,0418 e 0,1118, de modo que impossibilita dizer que as variâncias são diferentes. No caso do desvio padrão de 5, observa-se também que não há interseção entre os valores da média, permitindo dizer que as médias são diferentes. Avaliando os intervalos para a variância obtém-se interseção na região entre 0,0616 e 0,3725, de modo que não é possível dizer que as variâncias são diferentes.


O teste F para ambos os casos possui o mesmo intervalo, ou seja, $0,2484 < F < 4,026$ e os valores de F calculados são 2,6316 e 1,1649 para desvios de 0,1 e 5, respectivamente. Dessa forma, pode-se afirmar com 95% de confiança que os conjuntos amostrais para o critério AES, com relação à influência do número de partículas, possuem médias distintas, porém, pelo valor apresentado pelo teste F esses conjuntos de dados provavelmente apresentam a mesma variância.

Com base na discussão realizada acima, pode-se concluir que um aumento no número de partículas de forma semelhante ao observado para o RMS, também ocasiona uma melhora no valor do AES, ou seja, uma diminuição no valor do erro relacionado ao controle.

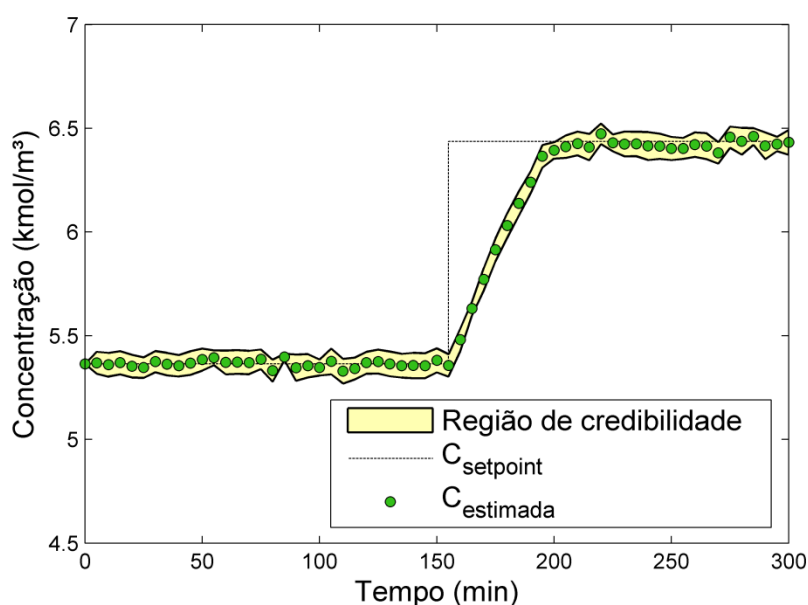
Para o desvio padrão da função de verossimilhança do segundo filtro, nota-se que um maior valor desse parâmetro leva a uma melhora em relação ao erro da estimativa (RMS). Contudo, quando se analisa o valor do erro ligado à variável controlada, esse aumento ocasiona maiores valores para o erro AES. O aumento no número de partículas possibilita uma melhora em ambos os critérios de avaliação em relação ao erro da estimativa (RMS) e o erro de controle (AES). Dessa forma, considerando que o objetivo dessa simulação e o critério para a escolha da melhor configuração estão baseados em um valor mínimo possível para esses parâmetros, a melhor configuração para o CPF-MPC é obtida ao utilizar o maior número de partículas (nesse caso, usam-se 100 partículas) e o menor valor de desvio padrão para o segundo filtro ($0,1^{\circ}\text{C}$). Como o tempo médio de ação do filtro foi muito baixo e inferior ao tempo de amostragem considerado no processo (1 minuto), ele não foi considerado um fator limitante para a escolha do número de partículas. Dessa forma, esta configuração foi utilizada no esquema de controle proposto neste estudo de caso.

6.1.2 *Comparação entre o CPF-MPC e o PF-MPC*

A fim de obter comparações justas, as restrições e as sequências de ruído são mantidas as mesmas ao serem utilizadas para ambas as simulações. A Figura 17 apresenta a comparação do desempenho do CPF-MPC e o PF-MPC. A região amarela é denominada região de credibilidade, a qual foi bem pequena para ambas as simulações, o que significa que a solução do PF é confiável e as possíveis soluções giram em torno de uma pequena região.



(A)



(B)

Figura 17 - Comportamento da concentração para o esquema de controle (A) CPF-MPC e (B) PF-MPC, com restrições do tipo “túnel”.


Os resultados para os critérios de avaliação RMS e AES são apresentados pela Tabela 16. Pode-se observar que o RMS foi pequeno para ambos os esquemas de controle, essa afirmação pode ser observada ao comparar o valor do erro médio em relação à magnitude da condição inicial da concentração de A, de forma que o erro representa aproximadamente 0,5% desse valor. Essa observação confirma as informações da literatura, que afirma sobre a eficiência do PF em estimar estados, mesmo quando é necessário observar restrições impostas pelo sistema. Observa-se

também uma melhora significativa para os valores do RMS para o CPF-MPC (que em termos percentuais giram em torno de 4,13%). Com relação aos valores da soma do erro absoluto (AES), observa-se que o PF-MPC apresentou menores valores em relação ao CPF-MPC (decréscimo de aproximadamente 2%), o que significa que para este esquema de controle os valores estimados estiveram mais próximos do *setpoint* do processo.


Tabela 16 - Critérios de desempenho CPF-MPC e PF-MPC.

Esquema de controle	N	RMS	AES
CPF-MPC	100	0,0278	6,0001
PF-MPC	100	0,0290	5.8679

Contudo, um dos objetivos dessa simulação também foi avaliar se as restrições para a temperatura do reator foram obedecidas. A Figura 18 apresenta o comportamento dinâmico da temperatura do reator para os esquemas de controle (A) CPF-MPC e (B) PF-MPC. É possível observar que na simulação para o CPF-MPC a temperatura obedeceu aos limites impostos pelo sistema, enquanto para o PF-MPC essa limitação imposta pelo processo foi violada.



(A)



(B)

Figura 18 - Comportamento da temperatura para o esquema de controle (A) CPF-MPC e (B) PF-MPC, com restrições do tipo “túnel”.


Como discutido acima, ao comparar os valores de RMS o CPF-MPC possui melhores valores que mostram um melhor desempenho na estimativa. Contudo, para o avaliador AES o PF-MPC é quem possui menores valores, mostrando um melhor comportamento para o controle da concentração do reagente A. Essa melhora do PF-MPC em relação ao CPF-MPC referente a valores estimados mais próximos do *setpoint* está relacionada ao fato de neste algoritmo não haver uma preocupação em atender as restrições impostas para a temperatura do reator.

Dessa forma, não havendo um tratamento para a limitação da temperatura, o controle da concentração do reagente A foi garantido, sem que fosse observado um quadro em que esses limites fossem obedecidos. Em contrapartida, para o CPF-MPC houve uma busca por dar importância tanto para o controle do reagente A quanto para o atendimento das restrições na temperatura, ocasionando um leve aumento nos valores de AES.


Além disso, nota-se que devido ao valor do desvio padrão da função de verossimilhança do segundo filtro de partículas igual a 0,1, o PF-MPC tenta manter, sem sucesso, a temperatura dentro da região de restrição. Uma melhora e uma busca para atender essa limitação do processo poderia ser observada ao aumentar o valor desse desvio padrão (o que já foi visto que acarreta também em um aumento no valor do AES) e poderia assim, dar uma menor importância ao controle de C_a e oferecer uma maior importância às restrições na temperatura do reator, o que ocasionaria uma piora no controle para o PF-MPC.

6.1.3 Comparação entre o CPF-MPC e o UKF-MPC

As restrições e as sequências de ruído são mantidas as mesmas ao serem utilizadas para ambas as simulações, com o intuito de obter comparações justas. A Figura 19 apresenta a comparação do desempenho do CPF-MPC e o UKF-MPC para a variável controlada C_a . Observa-se que o CPF-MPC apresenta melhor comportamento em relação ao UKF-MPC no que diz respeito ao acompanhamento da estimação da concentração em relação ao valor desejado para essa variável em virtude de uma perturbação programada de 20% em seu valor desejado. Essa melhora no desempenho é percebida, pois, o primeiro trata além das restrições na variável manipulada, também das restrições nos estados estimados, além de enviar ao segundo filtro como informação inicial para o cálculo da ação ótima de controle um valor otimizado com base no *setpoint* da concentração e das restrições na temperatura.



(A)



(B)

Figura 19 - Comportamento da concentração para o esquema de controle (A) CPF-MPC e (B) UKF-MPC, com restrições do tipo “túnel”.

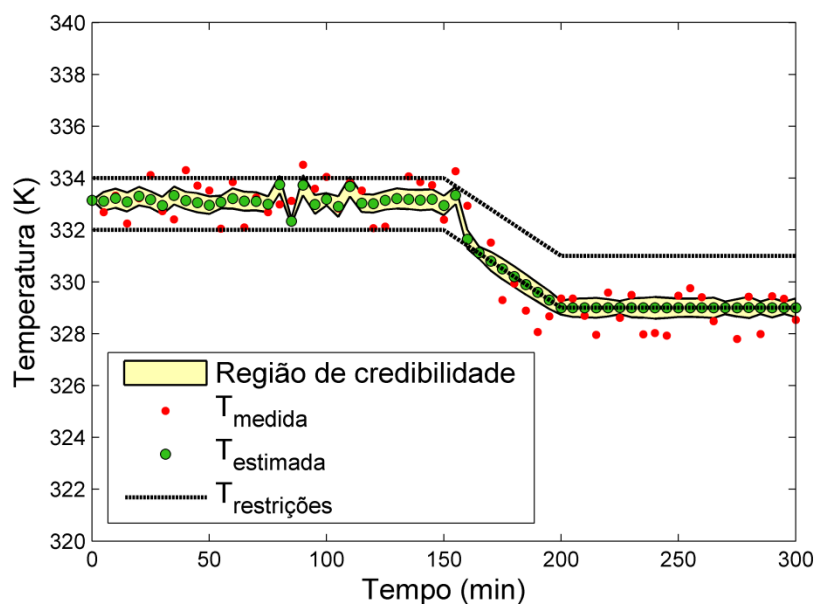
Os resultados para os critérios de avaliação RMS e AES são apresentados pela Tabela 17. É possível notar valores bem pequenos para o RMS para ambos os esquemas de controle (em torno de 0,5% para o CPF-MPC e 0,67% para o UKF-MPC), confirmando a literatura, que afirma sobre a eficiência dos filtros PF e UKF no cálculo da estimativa dos estados. Nota-se também um aumento no RMS de aproximadamente 29,49% para o UKF-MPC em relação ao CPF-MPC, o que pode ser explicado pelas melhoras já listadas acima acerca desse algoritmo. Com relação

ao AES, o CPF-MPC apresentou valores mais baixos em relação ao UKF-MPC, representando valores estimados mais próximos do *setpoint* do processo. Houve um acréscimo no valor do AES para o UKF-MPC de aproximadamente 26,77%, demonstrando a eficiência da estratégia CPF-MPC em manter a concentração do reagente A em um valor mais próximo possível do desejado.

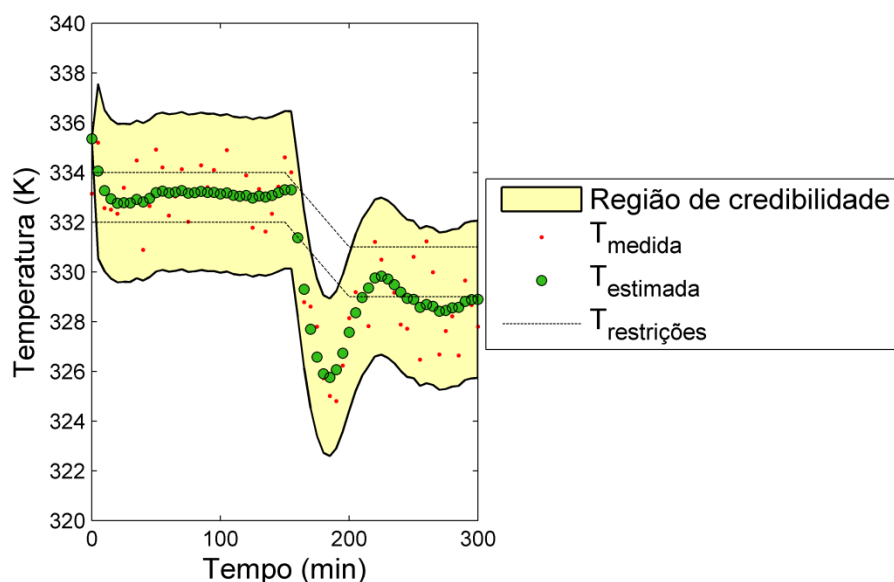
Tabela 17 - Critérios de desempenho CPF-MPC e UKF-MPC.

Esquema de controle	N	RMS	AES
CPF-MPC	100	0,0278	6,0001
UKF-MPC	-	0,0360	7,6065

O comportamento da temperatura do reator pode ser visualizado de acordo com a Figura 20. Nela é possível notar que, ao ser considerado restrições sobre a temperatura, o CPF-MPC obteve sucesso em manter o valor estimado dentro da região de restrição, enquanto o UKF-MPC não obteve sucesso nesse objetivo da simulação.



(A)




(B)

Figura 20 - Comportamento da temperatura para o esquema de controle (A) CPF-MPC e (B) UKF-MPC, com restrições do tipo "túnel".

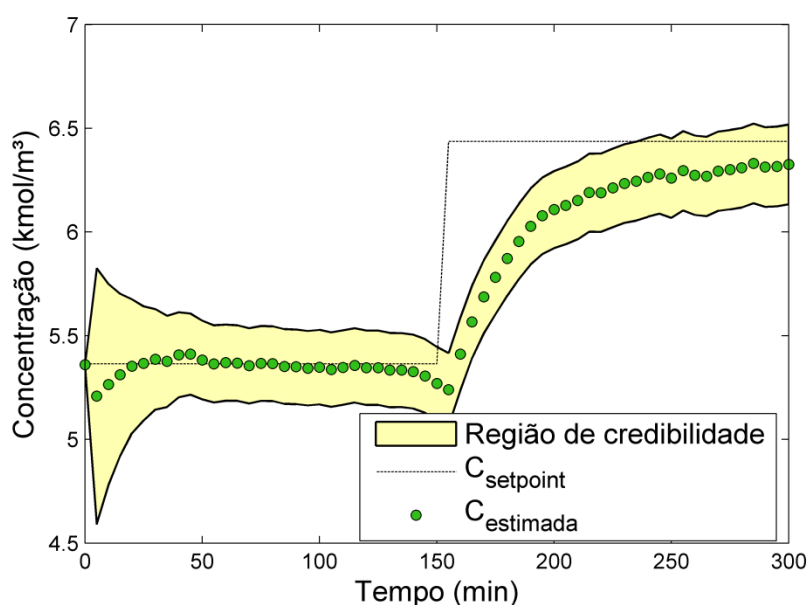
A região amarela no gráfico, denominada como região de credibilidade representa o intervalo possível de soluções para o estado. Dessa forma, nota-se que para o CPF-MPC, essa região é bem menor, o que significa uma boa estimacão. Entretanto, o UKF-MPC, mesmo com um bom desempenho na estimacão do estado, apresenta um intervalo muito maior, isto é, a região de possíveis soluções é muito maior, o que explica o fato de o UKF-MPC apresentar no interior da sua região de credibilidade todas as informacões de mediçãõ.

6.1.4 *Comparação entre o CPF-MPC e o CUKF-MPC*

A Figura 21 apresenta os resultados para o comportamento da concentração do reator para o caso com restrições do tipo “túnel”, usando os esquemas de controle (A) CPF-MPC e (B) CUKF-MPC. Em comparação com o CUKF-MPC, o CPF-MPC apresenta um melhor desempenho ao lidar com restrições sobre as estimativas do processo não linear. Uma explicação para esse comportamento se dá pelo fato de o UKF ter uma flexibilidade limitada, que pode ser relacionada à sua seleção determinística de pontos sigma, além de assumir que a distribuição seja gaussiana, mesmo após a transformação UT.



(A)



(B)

Figura 21 - Comportamento da concentração para o controlador (A) CPF-MPC e (B) CUKF-MPC, com restrições do tipo “túnel”.


Os critérios de desempenho também foram utilizados nesta etapa de avaliação e são apresentados na Tabela 18. Ao avaliar o RMS é possível observar um pequeno valor para esse critério em ambos os esquemas de controle (que representa aproximadamente 0,5% para o CPF-MPC e 0,8% para o CUKF-MPC), apresentando mais uma vez a eficiência dos filtros na estimação de estados. Contudo, ao compará-los, observa-se uma melhora próxima de 37,24% para esse critério do CPF-MPC em relação ao CUKF-MPC. Avaliando o valor do AES, foi possível notar

que o CPF-MPC apresentou um valor bem menor (melhora de aproximadamente 45,83%), confirmando sua eficiência no controle da concentração do reator. É possível também observar que ao incorporar as restrições, o valor do RMS torna-se pior para o algoritmo que utiliza o UKF como estimador, comprovando a deficiência desse filtro em lidar com restrições.

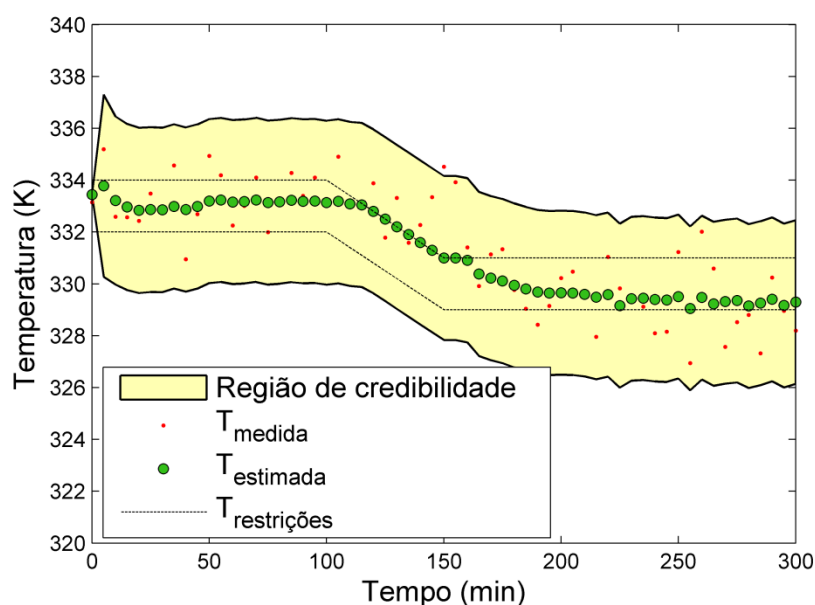
Tabela 18 - Critérios de desempenho CPF-MPC e CUKF-MPC.

Controlador	N	RMSE	AES
CPF-MPC	100	0,0278	6,0001
CUKF-MPC	-	0,0443	11,0769

Os resultados da simulação para a temperatura do reator na comparação entre o CPF-MPC e o CUKF-MPC, para o caso em que restrições do tipo “túnel” são implementadas, são apresentados na Figura 22, ao utilizar os esquemas de controle (A) CPF-MPC e (B) CUKF-MPC. Observa-se que em ambos os casos, o “caminho” proposto pela imposição da restrição é respeitado com sucesso no decorrer da simulação.



(A)



(B)

Figura 22 - Comportamento da temperatura para o esquema de controle (A) CPF-MPC e (B) CUKF-MPC, com restrições do tipo “túnel”.

Pela Figura 22 é possível notar que em ambos os casos o caminho é percorrido com êxito pelo controlador, limitando a temperatura em um limite superior e inferior. Shao, Huang e Liu (2010) afirmam em seu trabalho que o UKF apresenta relativas falhas ao tratar com restrições sobre os estados estimados. Segundo os mesmos autores, o PF por sua vez, apresenta um melhor desempenho ao tratar com restrições sobre os processos. Sendo assim, por meio da Figura 22, é possível perceber um comportamento mais satisfatório do CPF-MPC com restrição em

comparação ao CUKF-MPC, relacionado à dificuldade do UKF em realizar estimação com restrições.

6.2 Resultados: Estudo de caso 2

Para a implementação do CPF-MPC, foram utilizados um horizonte de predição igual a 5 min, um tempo de amostragem de 20s, o número de partículas foi 100 e os limites das restrições giraram em torno de 3% acima e abaixo do *setpoint* da concentração de B. A incerteza da geração das partículas é 1% do valor da condição inicial. Dentre esses valores, o tempo de amostragem foi determinado através da literatura e os demais considerados de maneira aleatória.

Os testes realizados foram: variação do *setpoint* da concentração do reagente B numa razão constante (desvio rampa), de modo que as restrições acompanhem essa variação; e perturbação nas entradas (C_{af} e T_f) os quais foram organizados conforme a Tabela 19. As seguintes situações foram avaliadas:

1. Sem distúrbios no processo;
2. Perturbação no *setpoint* da concentração do reagente B;
3. Perturbação na concentração de alimentação do reagente A;
4. Perturbação na temperatura de alimentação do reator.

Tabela 19 - Planejamento de distúrbios para avaliação de desempenho do CPF-MPC.

Caso	t < 1240 s	t ≥ 1240 s
1	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$
2	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$	$C_{b,set} = 1,09 \text{ mol/L} - 0,006 * C_{b,set}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$
3	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 7,1 \text{ mol/L}$
4	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 104,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$	$C_{b,set} = 1,09 \text{ mol/L}$ $T_0 = 94,9 \text{ °C}$ $Ca_0 = 5,1 \text{ mol/L}$

Os resultados das simulações foram mostrados para as quatro situações testadas conforme os subitens seguintes referentes a este estudo de caso.

6.2.1 Sem distúrbio no processo

Neste caso, não foram realizadas perturbações. A Figura 23 mostra o comportamento obtido para as concentrações dos reagentes A e B, para a temperatura do reator T_r .

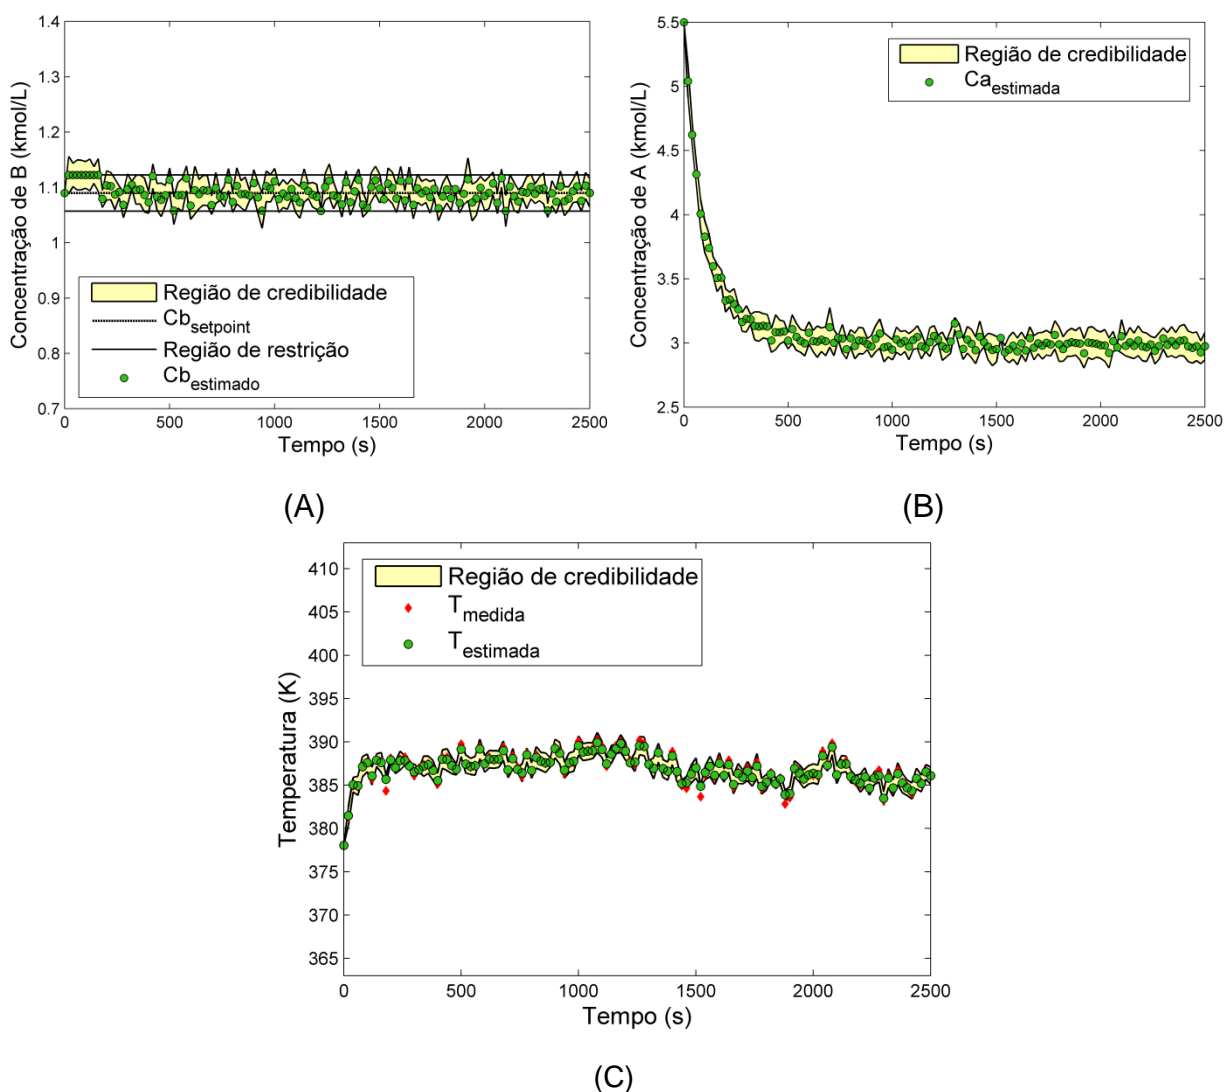


Figura 23 - Comportamento da Concentração do reagente A e B, e da temperatura do reator (C), quando não são consideradas perturbações no processo.

Observa-se a partir da Figura 23 que na ausência de perturbação o controlador se mostrou eficiente, mantendo a concentração do reagente B dentro da região de restrição desejada e garantindo valores próximos ao *setpoint*. Além disso, o controlador garantiu o processo estável durante toda a simulação, sem apresentar variações e instabilidades abruptas nos perfis avaliados.

A Figura 24 apresenta o comportamento dinâmico para as variáveis manipuladas F/V_r e Q_j na simulação do controle de C_b por meio do algoritmo CPF-MPC.




Figura 24 – Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, quando não são consideradas perturbações no processo.

Em virtude do caráter levemente oscilatório da variável controlada, as variáveis manipuladas também apresentaram um comportamento oscilatório durante a simulação.

6.2.2 Perturbação no setpoint da concentração do reagente B

Visando avaliar a eficácia do controlador proposto, foi realizado um teste servo no setpoint da concentração do reagente B. A ideia consistiu em variar o setpoint numa razão constante (desvio rampa) de modo que as restrições acompanhem essa variação. Então, foi possível demonstrar o comportamento das concentrações de A e B, bem como da temperatura T_r , garantindo que as restrições para a concentração do produto desejável fossem obedecidas ao longo do tempo, conforme pode ser visualizado pela Figura 25.

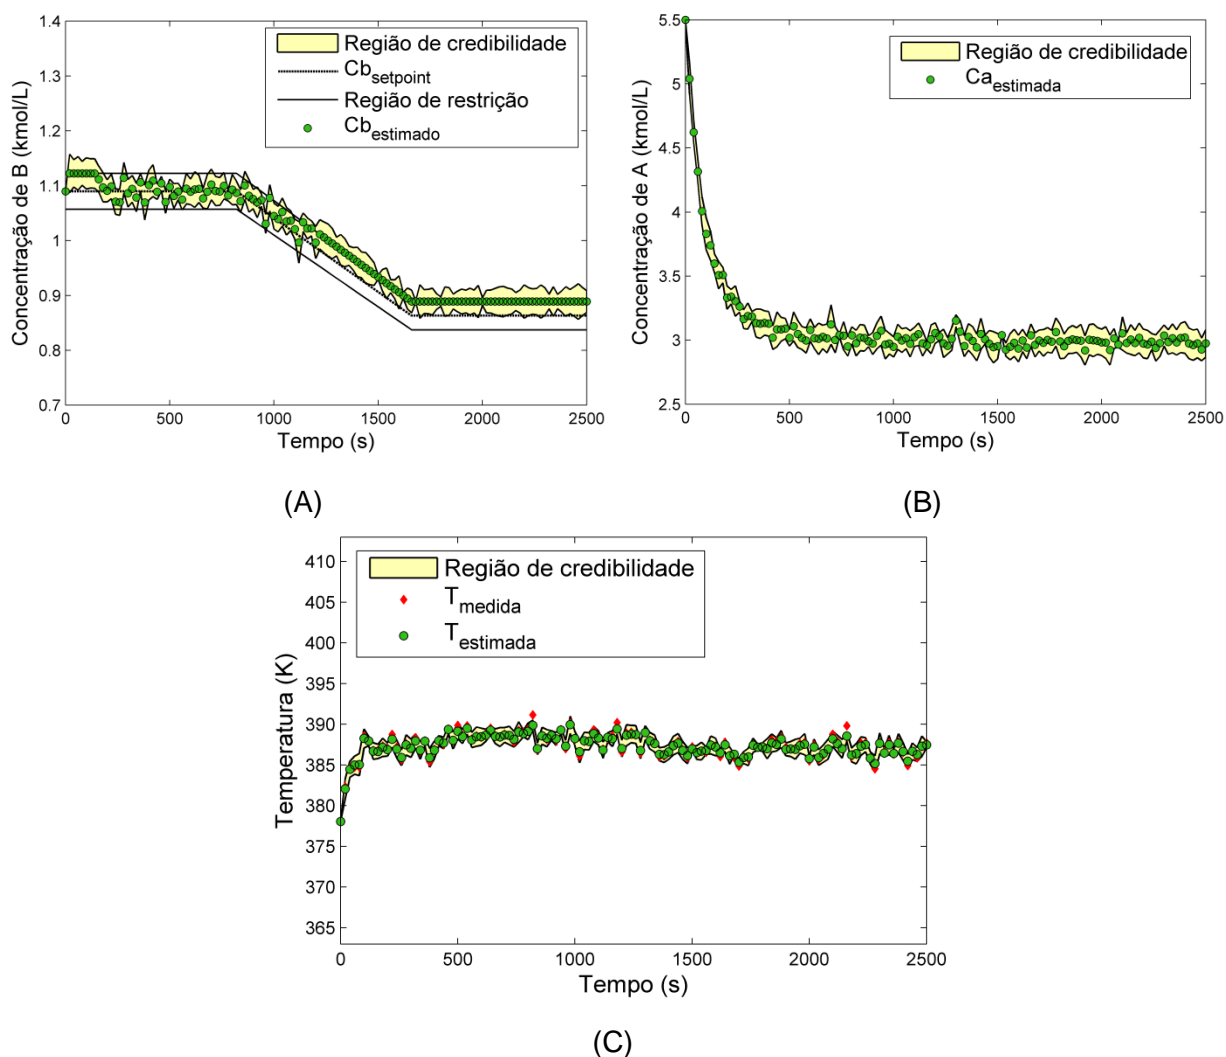


Figura 25 - Comportamento da concentração de A e B, e da temperatura do reator (C), considerando um teste servo no *setpoint* da concentração de B.

Como mostra a Figura 25, foi possível notar que o controlador conseguiu manter a concentração do reagente B na faixa desejada, mesmo diante de uma perturbação no seu *setpoint*. Em comparação com a Figura 23, observa-se que, mesmo em virtudes de alterações no *setpoint* da concentração do reagente B, a temperatura do reator e a concentração do reagente A não sofreram grandes alterações, confirmando a eficácia do esquema proposto em controlar mesmo em virtude de uma perturbação no *setpoint* da concentração do reagente B.

A Figura 26 apresenta o comportamento das variáveis manipuladas, para a condição em que ocorre perturbação programada no *setpoint* da variável controlada do sistema.

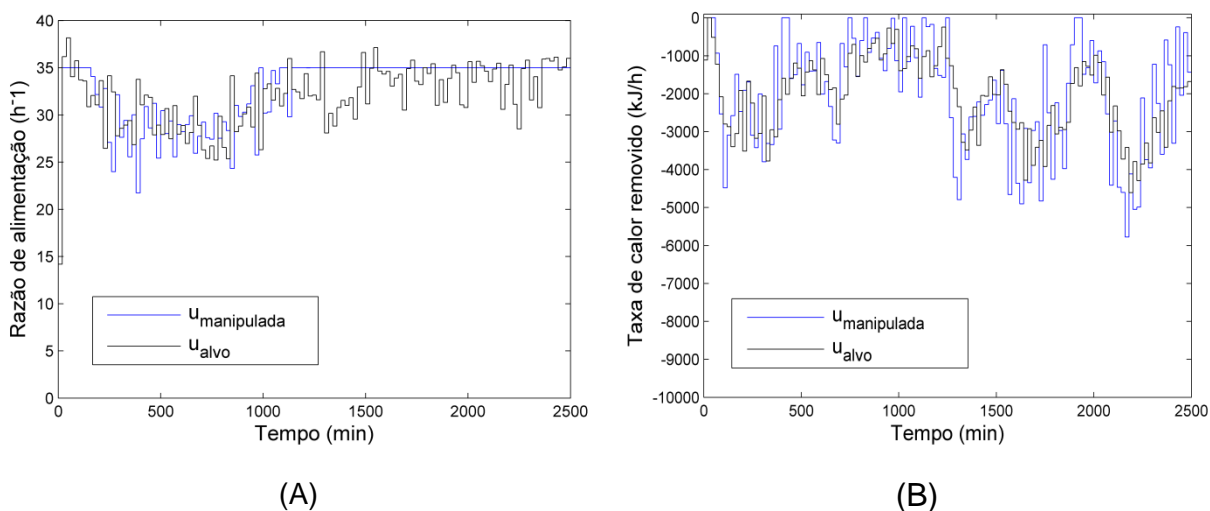


Figura 26 – Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, considerando um teste servo no *setpoint* da concentração de B.

Como consequência do deslocamento na concentração do reagente B as variáveis manipuladas apresentam comportamento oscilatório no intervalo de tempo de simulação. Esse comportamento pode ser explicado em virtude de o controlador sempre tentar superar o deslocamento na variável controlada alterando os valores das manipuladas.

6.2.3 Perturbação na concentração de alimentação do reagente A

Neste caso, foi aplicado um degrau de 2 mol/L na concentração de alimentação de A. A Figura 27 apresenta o comportamento obtido para as concentrações dos reagentes A e B, bem como o da temperatura do reator.

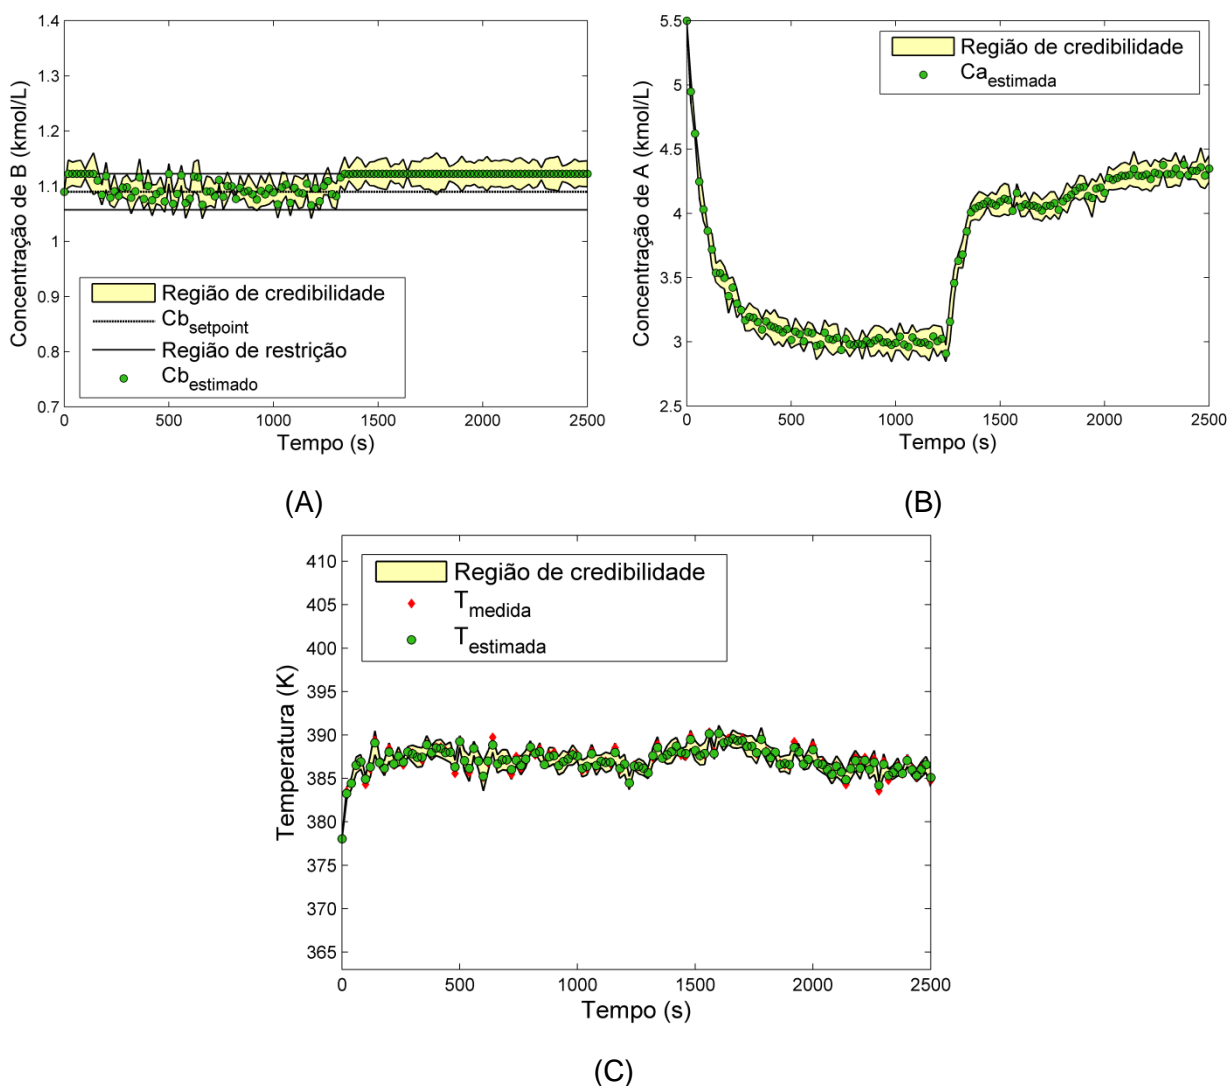


Figura 27 - Comportamento da concentração de A e B, e da temperatura do reator (C), considerando uma perturbação na concentração de alimentação do reagente A.

Neste caso, onde há perturbação positiva na concentração do reagente A na corrente de alimentação, é possível observar que no momento da perturbação, o caráter otimizador do algoritmo CPF-MPC traça uma nova trajetória para a variável controlada. Contudo, percebe-se que mesmo em virtude desse comportamento, a faixa desejada para a região de restrição da concentração do reagente B não foi violada.

A Figura 28 apresenta o comportamento das variáveis manipuladas, para a condição em a perturbação é programada sobre a concentração de alimentação do reagente A.

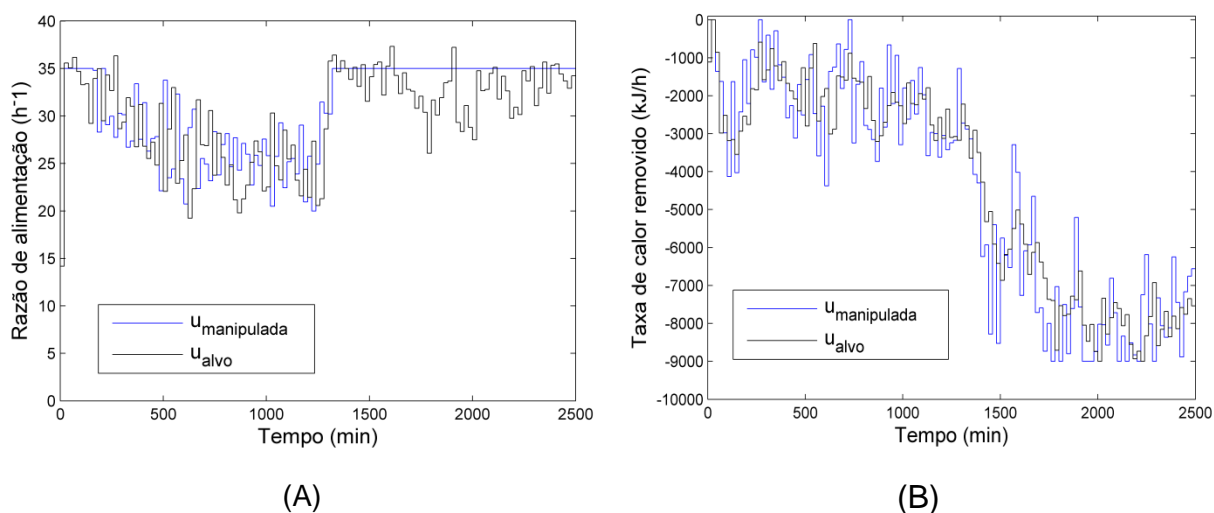


Figura 28 – Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, considerando uma perturbação na concentração de alimentação.

Na Figura 28, percebe-se que as variáveis manipuladas atuam com o intuito de rejeitar a perturbação na concentração do reagente A na corrente de entrada, ficando a taxa de calor em um nível mais baixo e a razão de alimentação em um nível mais elevado após a perturbação visando compensar a perturbação ocorrida, com ambas as variáveis manipuladas atuando a fim de garantir a concentração do reagente B na faixa desejada.

6.2.4 Perturbação na temperatura de alimentação do reator

Neste caso foi aplicado um degrau que consistiu em um decréscimo de 10°C na temperatura de alimentação do reator. A Figura 29 mostra o comportamento obtido para as concentrações de A e B, bem como da temperatura do reator para esse teste.

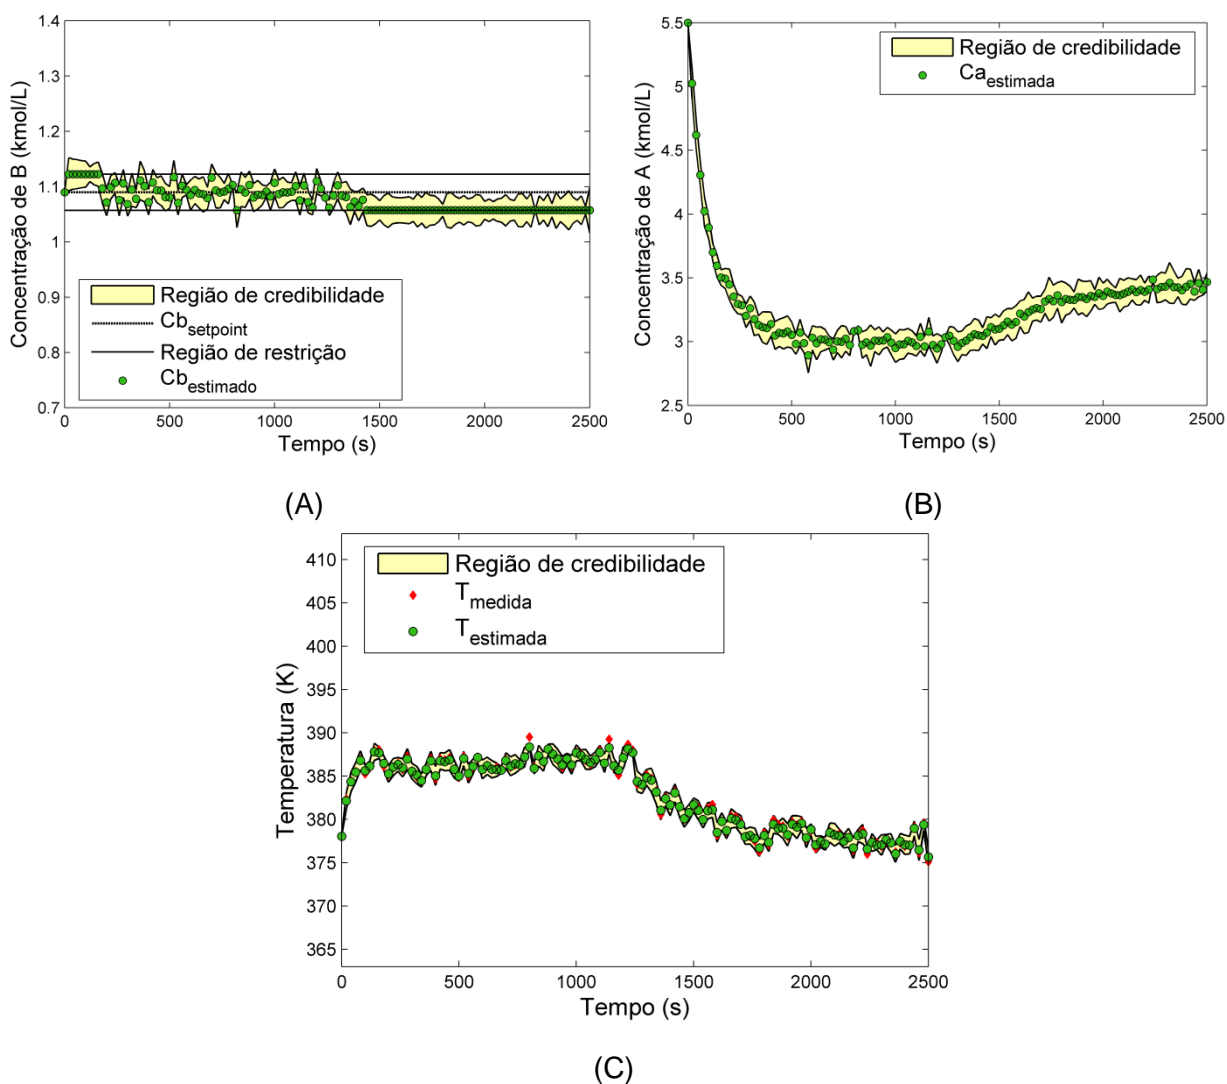


Figura 29 - Comportamento da concentração de A e B, e da temperatura do reator considerando um distúrbio na temperatura da alimentação.

Neste caso, há um decréscimo na temperatura de alimentação do reator em 10°C . Uma menor temperatura de alimentação promove uma redução na temperatura da mistura reacional. Nesta condição, há um favorecimento da reação em série ($B \rightarrow C$) em detrimento da reação principal ($A \rightarrow B$). Tal fato pode ser explicado ao ser analisado a entalpia das reações, que indicam que a reação em série é uma reação exotérmica e a reação principal uma reação endotérmica. Sabe-se que do ponto de vista cinético uma reação exotérmica é favorecida com a diminuição da temperatura do sistema. Isso ocorre porque segundo o princípio de Le Chatelier, se um sistema em equilíbrio sofre alguma perturbação (como a variação da temperatura) ele tende a minimizar essa perturbação. Sendo assim, como a reação exotérmica desprende calor, ela atua então minimizando os efeitos da diminuição da temperatura do sistema. Contudo, o controlador foi capaz de intervir e manter a concentração de B dentro do intervalo desejado mesmo em face desta condição adversa.

Figura 30 apresenta o comportamento das variáveis manipuladas, para a condição em que não há perturbação programada no sistema.




Figura 30 - Comportamento dinâmico da (A) razão de alimentação e (B) da quantidade de calor removido, considerando um distúrbio na temperatura de alimentação.

Os quatro casos avaliados representam situações possíveis em uma operação real. Um erro do operador ou alguma falha mecânica pode alterar as condições de alimentação do reator e o sistema de controle deve ser capaz de lidar com essas situações, mantendo o processo na condição desejada. O CPF-MPC foi capaz de manter a concentração de B no seu intervalo permitido, mesmo em face de várias condições adversas, e não foi observada nenhuma violação da região de restrição que limitou a concentração de B em 3% em torno do seu ponto de ajuste, demonstrando a capacidade do esquema proposto em lidar com o modelo não linear para um CSTR não isotérmico com reação de Van der Vusse.

Por meio destes comportamentos, é possível notar que o processo acompanha o *setpoint* em todo o tempo de simulação. É possível também visualizar que o controlador mantém o processo de Van der Vusse estável durante toda simulação, fato extremamente importante ao avaliar um processo não linear e bastante instável como este. Foi possível garantir que a concentração não violasse um percentual de seu valor desejado. Sendo assim, a mesma oscilou entre os 3%, mesmo quando submetida a testes de desempenho.

Vale a pena ressaltar que por ser um problema bastante estudado na área de controle, por seu caráter fortemente não linear, apresentar inversão de ganho, multiplicidade de entradas, resposta inversa e comportamento de fase não mínima, a cinética de Van der Vusse precisa de que seus parâmetros sejam bem ajustados, além de se ter um cuidado quanto ao tempo de amostragem, que se torna um ponto

crucial para o bom funcionamento dos controladores ao garantir a estabilidade nestes tipos de processos. Pode-se então dizer que o controlador preditivo associado ao filtro de partículas apresentou bom desempenho, conseguindo garantir o processo sempre perto do valor desejado para a concentração de B. O CPF-MPC foi capaz de manter a estabilidade do processo, não observando oscilações e variações abruptas nos parâmetros operacionais.

6.3 Resultados: Estudo de Caso 3

A fim de comparar a eficiência do controlador PF-MPC proposto por Stahl e Hauth (2011) e tomado por base neste trabalho, o mesmo foi testado em um problema com um grau de complexidade alto e bastante estudado em Engenharia Química. Os circuitos de fragmentação e classificação de minério de ferro são controlados, em sua maioria, por controladores clássicos, do tipo PI. Desse modo, o controlador PF-MPC foi comparado a essa classe de controladores, como modo de avaliar sua aplicação.

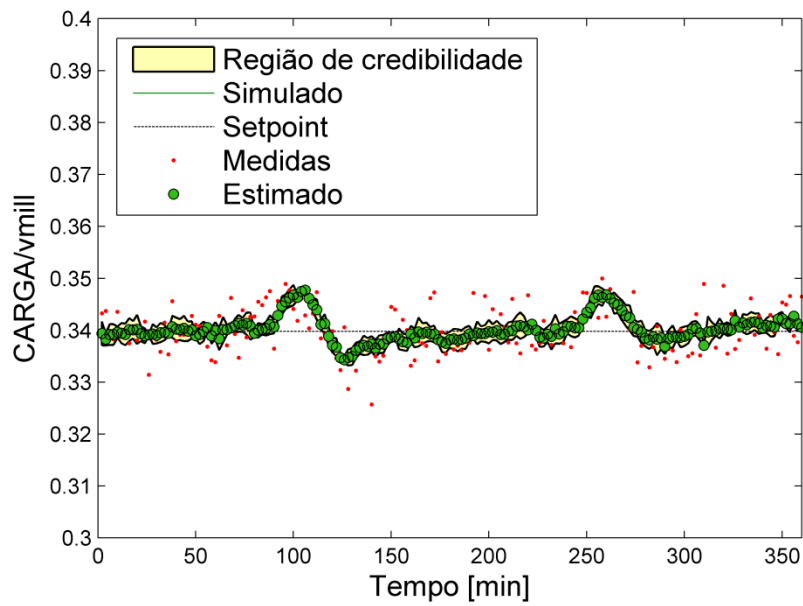
A fim de obter comparações justas, as sequências de ruído são mantidas as mesmas para ambas as simulações e as restrições não foram levadas em conta na implementação do algoritmo. Além disso, o algoritmo do arranjo de controle foi mantido o mesmo para ambos os casos, mudando apenas o controlador da camada supervisorio, ora PF-MPC, ora PI.

Desse modo, foi possível a implementação do controlador PF-MPC e posterior comparação com o PI. Em um primeiro momento, essa comparação foi realizada considerando degraus nas variáveis controladas PDE e VR e, posteriormente, foram realizados testes regulatórios em distúrbios do processo, para ambos os casos.


6.3.1 *Perturbação nas variáveis controladas PDE e VR*

As Figuras 31, 32 e 33 apresentam o comportamento das variáveis controladas (CARGA, PDE e VR) para (A) o caso em que o esquema com o controlador PF-MPC

foi utilizado na camada supervisória e para (B) o caso em que o esquema com o controlador PI foi utilizado quando são submetidos aos testes servos propostos.

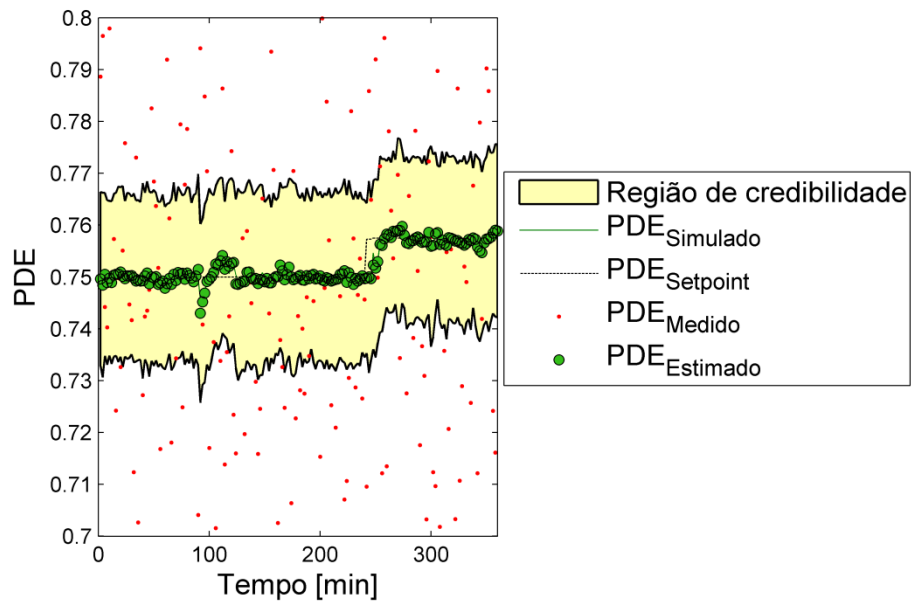


(A)




(B)

Figura 31 - Comportamento da variável controlada CARGA, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nas variáveis controladas PDE e VR.




(A)




(B)

Figura 32 - Comportamento da variável controlada PDE, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nas variáveis controladas PDE e VR.



(A)



(B)

Figura 33 - Comportamento da variável controlada VR, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nas variáveis controladas PDE e VR.

De acordo com a Figura 31, pode-se observar que para ambos os controladores, a variável controlada CARGA apresentou comportamento semelhante nas simulações. Isso decorre do fato de que, em ambos os casos, a variável foi controlada considerando os mesmos parâmetros de sintonia do controlador PI, além de utilizar como variável manipulada AM. Observa-se que em aproximadamente 1h30 de simulação, quando há uma mudança no *setpoint* de VR, a CARGA precisa desviar-

se do seu valor desejado para permitir o decréscimo de VR. O mesmo comportamento pode ser visto quando ocorre o desvio no *setpoint* de PDE (em aproximadamente 2h de simulação), comportamento este previsto conforme demonstrado por Van der Westhuizen e Powell (2006). Segundo esses autores, é necessário, em alguns casos, que a CARGA se desvie de seu *setpoint* para que um valor específico de PDE seja alcançado, desde que o mesmo varie em torno de sua condição nominal, fato que pode ser notado em ambas as simulações.

A Figura 32 possibilita a comparação do controle para a variável PDE. Essa variável é muito importante nesse sistema, pois a mesma garante a qualidade do material produzido pelo circuito. Sendo assim, é necessário que, ao ser submetido a perturbações no seu *setpoint*, o controlador apresente resposta rápida no alcance desse novo valor desejado. Por ser ligada a qualidade do material produzido, é necessário também que essa variável sofra o mínimo com as perturbações em outras variáveis do processo. Conforme visualizado na Figura 32, o controlador PF-MPC apresentou essas características de robustez e estabilidade, alcançando o novo *setpoint* após o degrau no seu valor com um tempo menor de resposta, demonstrando a robustez do método proposto. Ademais, a estratégia de controle proposta neste trabalho também foi a que menor sofreu variações em decorrência da perturbação em SVOL, garantindo estabilidade ao processo em virtude de perturbações programadas em outra variável controlada.

Na Figura 33, observa-se o comportamento da variável VR para ambos os esquemas de controle. Como já mencionado, esta variável não tem impacto sobre o estado estacionário do sistema. Desse modo, o *setpoint*, bem como seu valor estimado precisam apenas respeitar a região de restrição imposta pelo sistema.

Conforme ilustrado nas Figuras 31, 32 e 33, as estimativas foram precisas, ou seja, mesmo em virtude de ruídos nas variáveis medidas, o filtro foi capaz de amenizá-las e garantir uma boa estimativa.

As Figuras 34, 35 e 36, apresentam, respectivamente, o comportamento das variáveis manipuladas AM, AAR e AH para o esquema de controle com o controlador PF-MPC e para o esquema com o controlador PI para a camada supervisória (controle do PDE), quando este sistema sofre perturbações nos valores desejados para as variáveis controladas VR e PDE.




Figura 34 - Comportamento da variável manipulada AM, para perturbações nas variáveis controladas PDE e VR.




Figura 35 - Comportamento da variável manipulada AAR, para perturbações nas variáveis controladas PDE e VR.




Figura 36 - Comportamento da variável manipulada AH, para perturbações nas variáveis controladas PDE e VR.

Para que o controle da CARGA fosse estabelecido, a variável manipulada AM sofreu alterações ao longo da simulação. Também é possível perceber que no tempo de simulação próximo de 1h30, quando há perturbação no *setpoint* da variável VR, é sentida alterações na quantidade de água adicionada ao misturador (AAR). A mudança programada no *setpoint* da variável controlada PDE é gerenciada também por uma manipulação da variável AH, o que possibilita que seja alcançado o novo valor desejado de PDE.

A Tabela 20, mostra o erro médio quadrático (RMS) para cada variável estimada, e também o somatório do erro absoluto (AES), para as variáveis controladas.

Tabela 20 - Análise do RMS e AES para escolha da melhor estratégia de controle, em virtude das perturbações no *setpoint* de VR e PDE.


VARIÁVEL	ESQUEMA DE CONTROLE			
	Com o PF-MPC		Com o PI	
	RMS	AES	RMS	AES
X_{am}	0,0054	-	0,0039	-
X_{sm}	0,0055	-	0,0037	-
X_{fm}	0,0017	-	0,0016	-
X_{rm}	0,0020	-	0,0019	-
X_{em}	0,0020	-	0,0020	-
X_{ar}	0,0174	-	0,0097	-
X_{sr}	0,0063	-	0,0035	-
X_{fr}	0,0013	-	$9,2360 \times 10^{-4}$	-
CARGA	$2,9138 \times 10^{-4}$	0,5524	$2,8370 \times 10^{-4}$	0,4638
VR	0,0237	66,4562	0,0131	55,6698
PDE	$6,8842 \times 10^{-4}$	0,3493	$6,6255 \times 10^{-4}$	0,5918
THP	0,0359	-	0,0358	-
P_M	0,0167	-	0,0153	-
DAH	$2,5064 \times 10^{-4}$	-	$2,1823 \times 10^{-4}$	-

Conforme mostrado, para ambos os casos, a estimativa alcançou um grau de precisão relativamente bom, conforme demonstrado pelo valor do RMS alcançado ao longo das simulações. Para o esquema de controle em que o PF-MPC foi utilizado na camada supervisória, o erro de medição mais elevado em valor absoluto foi para a variável X_{ar} , em termos de valores percentuais, o maior valor é para a variável X_{fr} (com erro em torno de 0,4642%), comprovando a qualidade da estimativa. Em uma comparação entre os valores de RMS para os dois esquemas é possível observar que, para o esquema em que o PI foi utilizado houve uma melhor estimativa, esse comportamento fica ainda mais notável ao visualizar os resultados para a variável controlada VR (em que o RMS para o esquema com o PF-MPC apresentou-se aproximadamente 80% maior). Por semelhante modo, em relação aos valores de AES para as variáveis controladas, há também esse comportamento (de maior erro para o esquema com PF-MPC) para as variáveis VR e CARGA. Contudo, como já mencionado anteriormente, o objetivo de controle desse estudo de caso é garantir a qualidade do produto em especificação. Tendo em vista isso, ao verificar os resultados do AES para o PDE é possível notar que, para o esquema de controle com PF-MPC, esse valor representa uma magnitude menor que aquele apresentado pelo esquema com o controlador PI (sendo este cerca de 73% maior). Tal afirmação também foi visualizada devido às oscilações e a distância entre o estimado e o valor desejado para o controlador no gráfico dessa variável. Mesmo


apresentando valores de maior magnitude para as demais variáveis, o esquema com o controlador PF-MPC em média apresentou erros relativamente pequenos e o menor erro para a variável de objetivo de controle. Dessa forma, justifica-se sua aplicação na busca por melhores resultados na produção do produto em especificação.

6.3.2 *Perturbação nos parâmetros*

De acordo com Olivier, Craig e Chen (2012) a rejeição de perturbações externas é de extrema importância na operação de moinho de minério de ferro. Buscou-se a qualidade de um produto consistente, enquanto os parâmetros do circuito mudam continuamente. No primeiro momento, foi realizada uma alteração na fração de rochas e finos que entram no processo (α_f e α_r). Esses valores são diminuídos de 0,05% em cada minuto durante 1h de simulação. Posteriormente, há um aumento nos parâmetros que se relacionam com a dureza do minério (ϕ_f e ϕ_r). O efeito dessas perturbações pode ser visualizado através das Figuras 37, 38 e 39, as quais mostram a resposta das variáveis controladas do sistema às variações destes parâmetros. São apresentados os comportamentos das variáveis controladas (CARGA, PDE e VR) para o caso do controle com PF-MPC e também apresenta para o controle que utiliza o PI.




(A)




(B)

Figura 37 - Comportamento da variável controlada CARGA, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r .




(A)




(B)

Figura 38 - Comportamento da variável controlada PDE, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r .



(A)



(B)

Figura 39 - Comportamento da variável controlada VR, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r .

Pela Figura 37, observa-se o comportamento da variável CARGA em decorrência de um decréscimo na fração de rochas e finos (α_f e α_r) do processo (entre 90 a 150min). O comportamento dessa variável ocorre em virtude do gradual aumento de AM necessário para compensar a ligeira diminuição da fração de rocha (α_f) que entra no circuito. As perturbações que ocorrem nos parâmetros que estão

relacionados à dureza do minério (ϕ_f e ϕ_r), ocasiona um aumento no valor da variável controlada CARGA. Esse fato pode ser explicado por haver um minério mais duro, que faz com que o mesmo permaneça um tempo maior no interior do moinho para a etapa de moagem, aumentando assim a quantidade de material no moinho. Como o objetivo de controle neste caso é a manutenção da qualidade do produto em especificação (PDE), não há muita resistência do processo quanto ao acréscimo do valor da variável CARGA.

O controle de PDE, como mostrado pela Figura 38, é também relacionado aos dois fenômenos. Quando há diminuição na fração de rocha, há uma tendência de PDE aumentar, uma vez que o controle não visa um ajuste firme na variável CARGA, essa pequena variação em PDE (0,02) é permitida para rejeição dos distúrbios do processo. No momento em que há um aumento na dureza do material, torna-se mais complicado sua quebra e o mesmo permanece no moinho, aumentando a quantidade de material (CARGA) no interior do mesmo. Para manter PDE no *setpoint*, a variável manipulada AH aumenta gradualmente.

A Figura 39 apresenta o comportamento da variável controlada VR considerando os dois casos. Como essa variável necessita de estar dentro do seu limite de restrição (2 a 20), o seu controle não foi de ajuste firme. Desse modo a mesma pode sofrer as consequências de um controle mais firme em PDE, variando de forma mais abrupta.

Conforme discutido anteriormente, o objetivo desse controle é manter a qualidade do produto de saída do processo. Dessa forma, visa-se a busca de um controlador que possua estabilidade e robustez no controle de PDE. Como observado pela Figura 38, o esquema de controle que utiliza do PF-MPC para seu controle apresentou melhores resultados.

As Figuras 40, 41 e 42 ilustram o comportamento da quantidade de minério adicionado ao moinho (AM), bem como a quantidade de água adicionada ao misturador para ajuste da densidade (AAR) e a taxa de alimentação de entrada de lama no hidrociclone (AH).




Figura 40 - Comportamento da variável manipulada AM, para perturbações nos parâmetros

$$\alpha_f, \alpha_r, \phi_f \text{ e } \phi_r.$$




Figura 41 - Comportamento da variável manipulada AAR, para perturbações nos parâmetros

$$\alpha_f, \alpha_r, \phi_f \text{ e } \phi_r.$$




Figura 42 - Comportamento da variável manipulada AH, para o esquema com o controlador (A) PF-MPC e (B) PI para perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r .

As Figuras 40, 41 e 42 demonstram que para o controle da variável CARGA fosse estabelecido, a variável manipulada AM sofreu alterações ao longo da simulação, conforme o comportamento apresentado no gráfico dessa variável. Conforme as muitas variações apresentadas no gráfico da variável controlada VR, é possível observar também que esse comportamento influencia diretamente na quantidade de água adicionada ao misturador (variável manipulada AAR). Com o objetivo de manter o produto de especificação (PDE) em seu valor desejado, é gerenciada também uma manipulação na variável AH, levando a mesma ao valor desejado para a variável PDE.

A Tabela 21 mostra o erro médio quadrático (RMS) para cada variável estimada, e também o somatório do erro absoluto (AES), para as variáveis controladas.

Tabela 21 - Análise do RMS e AES para escolha da melhor estratégia de controle, em virtude das perturbações nos parâmetros α_f , α_r , ϕ_f e ϕ_r .

VARIÁVEL	ESQUEMA DE CONTROLE			
	Com o PF-MPC		Com o PI	
	RMS	AES	RMS	AES
X_{am}	0,0071	-	0,0050	-
X_{sm}	0,0084	-	0,0057	-
X_{fm}	0,0017	-	0,0017	-
X_{rm}	0,0039	-	0,0038	-
X_{em}	0,0020	-	0,0020	-
X_{ar}	0,0249	-	0,0118	-
X_{sr}	0,0088	-	0,0041	-
X_{fr}	0,0020	-	0,0012	-
CARGA	$3,1764 \times 10^{-4}$	1,5003	$2,9890 \times 10^{-4}$	1,1905
VR	0,0337	182,7068	0,0158	118,2845
PDE	$7,7885 \times 10^{-4}$	0,6782	$7,2334 \times 10^{-4}$	1,7912
THP	0,0380	-	0,0369	-
P_M	0,0299	-	0,02	-
DAH	$2,9489 \times 10^{-4}$	-	$2,4988 \times 10^{-4}$	-

De acordo com a Tabela 21, para ambas as estratégias de controle, a estimativa alcançou um grau de precisão satisfatório, conforme pode ser visualizado ao avaliar o maior valor de RMS para os estados em cada um dos esquemas de controle ao longo da simulação: 0,0249 para a variável X_{ar} para o esquema com o controlador PF-MPC e 0,0118 também para a variável X_{ar} no esquema com o controlador PI. Em termos percentuais, a variável com maior percentual de erro foi a X_{fr} , com 0,714% para o esquema com o PF-MPC e 0,428% para o esquema com o PI, mais uma vez confirmando uma estimaco com baixo nvel de erro. Como os valores de erro so bem pequenos e relativamente prximos, garantindo uma boa estimaco para os dois esquemas de controle, uma anlise do AES pode dizer um pouco mais acerca da melhor estratgia de controle. Por meio desse parmetro  possvel notar que o controle das variveis (CARGA e VR) obtiveram um melhor desempenho para o esquema de controle que utiliza o PI na camada supervisria. Em contrapartida, que utiliza o PF-MPC no controle da varivel PDE apresentou melhores valores de AES para essa varivel (escolhida como objetivo de controle desse sistema, garantindo a qualidade do produto de especificaco). Como para as demais variveis, estimadas e controladas, h uma equivalncia nos resultados obtidos, essa melhora no controle de PDE (aproximadamente 62%) justifica a aplicaco do esquema de controle com o PF-MPC em relato ao PI na busca por um melhor desempenho da varivel que garante o produto de especificaco.

7 CONCLUSÕES E SUGESTÕES

O presente Projeto de Dissertação pretendeu contribuir como uma metodologia nova de controle preditivo estocástico utilizando filtro de partículas, abordando juntamente as restrições impostas pelos processos, denominada CPF-MPC. Este algoritmo foi testado em um modelo de um reator CSTR simples de primeira ordem e em um reator CSTR com reação de Van der Vusse. Este algoritmo aninha dois filtros de partículas SIR que são dedicados a tarefas complementares. O primeiro realiza a estimativa do estado no instante de tempo atual a partir de medidas com incertezas e o segundo PF realiza o controle do processo, por meio do cálculo da sequência ótima de entradas ao do horizonte de predição de acordo com a trajetória de *setpoint* esperada.

A principal contribuição é a incorporação de uma etapa de otimização e reamostragem para lidar com restrições sobre as estimativas dos estados (e não apenas sobre as variáveis de entrada, como a abordagem PF-MPC, encontrada na literatura). A abordagem CPF-MPC permite definir o horizonte de predição, o número de partículas e parâmetros importantes relacionados à sensibilidade a restrições e o *setpoint* desejado. A investigação do esquema CPF-MPC considerou o algoritmo SIR, além de diferentes números de partículas e restrições do tipo caixa e túnel para os dois exemplos simulados.

Além disso, a abordagem proposta nessa Dissertação foi comparada ao utilizar o mesmo arranjo de controle, com o UKF como estimador. A caracterização do erro absoluto, o tempo computacional médio e a região de credibilidade permitiram analisar o desempenho de controle. O esquema de controle permitiu reduzir incertezas de dados do processo corrompidos e estimar variáveis não medidas, enquanto as restrições foram obedecidas. Verificou-se que o filtro de partículas mostrou ser mais preciso estimador que o UKF. Além disso, em testes com restrição, o CPF-MPC conduziu a resultados satisfatórios garantindo o processo no *setpoint*, provando sua eficiência de controle. Em contraste, os resultados com UKF mostram desempenho limitado devido à sua limitação em lidar com restrições.

Observou-se também que o CPF-MPC apresentou resultados excelentes em relação ao sistema de reação de van der Vusse. Apesar das perturbações, a abordagem de controle manteve a concentração de produto desejado e a estabilidade do sistema. Discutiu-se também a necessidade de ajustar de forma cuidadosa os parâmetros do CPF-MPC. Os resultados demonstram o potencial do algoritmo proposto e o seu

sucesso ao lidar com controle de processos não lineares e complexos. O esquema de controle obteve desempenho satisfatório ao garantir estabilidade, qualidade de estimativa e respeito às restrições de processo.

O CPF-MPC conseguiu atingir com eficiência os objetivos de controle dos estudos de caso para o qual ele foi considerado, mantendo o *set point* da variável controlada em seu valor desejado, mesmo após perturbações programadas no sistema, além de não violar as restrições operacionais dos sistemas. As seguintes sugestões podem ser consideradas para trabalhos futuros:

- Avaliação do CPF-MPC em processos multivariáveis mais complexos, como o próprio problema do minério, sujeitos a perturbações do processo que possam levar a condições fora dos limites exigidos pelo sistema.
- Comparações do CPF-MPC com técnicas já bem difundidas e conhecidas, tais como controle PID.
- Estudar qual a razão dos testes para o desvio padrão do segundo filtro fornecer conclusões contrárias para os critérios RMS e AES, por exemplo, porque um aumento nesse valor favorece RMS e desfavorece AES.

8 REFERÊNCIAS

ABELL, P.; COATES, A.; MONTEMERLO, M.; NG, A. Y.; THRUN, S. Discriminative Training of Kalman Filters, **In Proceedings of Robotics: Science na Systems**, 2005.

AFSHARI, H. H.; GADSEN, S. A.; HABIBI, S. Gaussian Filter for Parameter and State Estimation: A General Review of Theory and Recent Trends, **Signal Processing**. Disponível em : <<http://dx.doi.org/10.1016/j.sigpro.2017.01.001>>. Acesso em 20 de jan. 2017.

AGACHI, P. S.; NAGY, Z. K.; CRISTEA, M. V.; IMRE-LUCACI, A. **Model Based Control**. Disponível em: <<https://books.google.com.br/books?id=kLeQqpbDj20C&pg=PA274&dq=Model+Base+d+Control.+aGACHI&hl=pt-BR&sa=X&ved=0ahUKEwisx9rukJHMAhWikJAKHY4KDjoQ6AEIHTAA#v=onepage&q=Model%20Based%20Control.%20aGACHI&f=false>>. Acesso em 15 abr. 2016.

ANDRIEU, C.; DOUCET, A.; SINGH S. S.; TADIC, V. B. Particle Methods for Change Detection, System Identification, and Control. **Proceedings of the IEEE**. v. 92, p. 423-438, 2004.

ARULAMPALAM, M. S.; MASKELL, S.; GORDON, N.; CLAPP, T. A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking, **IEEE Transactions on Signal Processing**, v. 50, p. 174-188, 2002.

BLACKMORE, L. A probabilistic Particle Control Approach to Optimal, Robust Predictive Control. **Computer Science and Artificial Intelligence Laboratory Technical Report**, 2006.

BOTCHU, S. K.; UNGARALA, S. Nonlinear model predictive control based on Sequential Monte Carlo state estimation. **Preprints of the 8th IFAC Symposium on Dynamics and Control of Process Systems**. v. 3, 2007.

CAMACHO, E. F.; BORDONS, C. Control predictivo: pasado, presente y futuro. **Revista Iberoamericana de Automática e Informática Industrial**. v. 1, p.5-28, 2004.

CARVALHO, R. F.; DIAS, A. C. S. R.; DA SILVA, W. B; DUTRA, J. C. S. Filtro de Partículas como observador online em um esquema de controle cascata para um reator contínuo, **XIX Encontro Nacional de Modelagem Computacional - ENMC**, João Pessoa, Anais ENMC, 2016.

CHEN, T.; MORRIS, J.; MARTIN, E. Dynamic data rectification using particle filters, **Computers & Chemical Engineering**, v. 32, p. 451-462, 2008.

CHEN, T.; MORRIS, J.; MARTIN, E. Particle filters for state and parameter estimation in batch process, **Journal of Process Control**, v.15, p. 665-673, 2005.

COETZEE, L. C. **Robust nonlinear model predictive control of a run-of-mine ore milling circuit**. Philosophae Doctoral (Electronic Engineering). University of Pretoria, 2009.

COETZEE, L. C.; CRAIG, I. K.; KERRIGAN, E. C. Nonlinear Model Predictive Control of a Run-of-Mine Ore Milling Circuit. **Proceedings of the 17th IFAC World Control**. Seoul, Korea, 2008.

COETZEE, L. C.; CRAIG, I. K.; KERRIGAN, E. C. Robust Nonlinear Model Predictive Control of a Run-of-Mine Ore Milling Circuit. **IEEE Transactions on control systems technology**. v. 18, p. 222-229, 2010.

CRAIG, I. K.; MACLEOD, I. M. Specification framework for robust control of a run-of-mine ore milling circuit. **Control Engineering Practice**. v. 3, p. 621-630, 1995.

CUELLAR, F. D. R. **Análise e implementação de estimadores de estados em processos químicos**. Tese (Doutorado em Engenharia). Escola Politécnica, Universidade de São Paulo, 2013.

DIAS, A. C. S. R.; DUTRA, J. C. S.; DA SILVA, W. B. Simulation and Control of a propylene polymerization reactor with material integration using software EMSO, **XXI Congresso Brasileiro de Engenharia Química**, Fortaleza, Anais do Congresso Brasileiro de Engenharia Química – COBEQ, 2016.

DOS SANTOS, J. E. S. **Controle preditivo não linear para sistemas de Hammerstein**, Tese (Doutorado em Engenharia Elétrica), Universidade Federal de Santa Catarina, 2007.

DOUCET, A.; GODSILL, S.; ANDRIEU, C. On sequential Monte Carlo sampling methods for Bayesian filtering. **Statistics and Computing**. v. 10, p. 197-208, 2000.

DURAIKI, R. G. **Controle preditivo não linear utilizando linearizações ao longo da trajetória**, Dissertação (Mestrado em Engenharia Química), Escola de Engenharia, Universidade Federal do Rio Grande do Sul, 2001.

DUTRA, J. C. S. **Controle de processos baseado em esquemas de reconfiguração**. Tese (Doutorado em Engenharia Química), COPPE, Universidade Federal do Rio de Janeiro, 2012.

EBINGER, B.; BOUAYNAYA, N.; POLIKAR, R.; SHTERENBERG, R. Constrained state estimation in particle filters, **Proc. IEEE**, p. 4050-4054, 2015.

GARCÍA, C. E.; MORSHEDI, A. M. Quadratic programming solution of dynamic matrix control (QDMC). **Chemical Engineering Communications**, v. 45, p. 73-87, 1986.

HENSON, M. A. Nonlinear model predictive control: current status and future directions. **Computer and Chemical Engineering**. v. 23, 187-202, 1998.

HODOUIN, D. Methods for automatic control, observation, and optimization in mineral processing plants. **Journal of Process Control**. v. 21, p. 211-225, 2011.

IKONEN, E. **Model Predictive Control and State Estimation**, 2013. Disponível em: < <http://cc.oulu.fi/~iko/SSKM/SSKM2012Book.pdf>>. Acesso em 20 dez. 2016.

JAZWINSKI, A. H. Stochastic Process and Filtering Theory, **New York: Academic Press**, 1970.

JULIER, J.; UHLMANN, J. Unscented filtering and nonlinear estimation, **Proceedings of the IEEE**, v. 92, p.401–422, 2004.

JULIER, S. J.; UHLMANN, J. K.; DURANT-WHYTE, H. F.; A new method for the nonlinear transformation of means and covariances in filters and estimators, **IEEE Transactions on Automatic Control**, v. 45, p. 477-482, 2000.

KANTAS, N.; MACIEJOWSKI, J. M.; LECCHINI-VISINTINI, A. Sequential Monte Carlo for Model Predictive Control. **LNCIS**. v. 384, p. 263-273, 2009.

KULIKOV, G. T.; KULIKOVA, M. V. Accurate state estimation in the Van der Vusse reaction, **IEEE Conference on Control Applications**, p.759-764, 2014.

KYRIAKIDES, I.; MORRELL D.; PAPANDREOU-SUPPAPPOLA, A. A particle Filtering Approach To Constrained Motion Estimation In Tracking Multiple Targets, in: **The 39th Asilomar Conference on Signals, Systems and Computer**, 2005.

LE ROUX, J. D.; CRAIG, I. K.; HULBERT, D. G.; HINDE, A. L. Analysis and validation of a run-of-mine ore grinding mill circuit model for process. **Minerals Engineering**. v. 43-44, p. 121-134, 2013.

LE ROUX, J. D.; OLIVIER, L. E.; NAIDOO, M. A.; PADHI, R.; CRAIG, I. K. Throughput and product quality control for a grinding mill circuit using non-linear MPC, **Journal of Process Control**, v. 42, p. 35-50, 2016.

LOPEZ, L.F. **Cyber-enabled Manufacturing Systems (CEMS): Model-based estimation and control of a solidification process**. Dissertation (Doctor of Philosophy) – The University of Texas at Austin, 2014.

LÓPEZ-NEGRETE, R.; PATWARDHAN, S. C.; BIEGLER, L. T. Constrained particle filter approach to approximate the arrival cost in Moving Horizon Estimation, **Journal of Process Control**, v.21, p.909-919, 2011.

MAGALHÃES, O. I. B.; **Desenvolvimento de um Sistema de otimização dinâmica em tempo real**, Dissertação (Mestrado em Engenharia Química), COPPE, Universidade Federal do Rio de Janeiro, 2010

MATTHEWS, B.; CRAIG, I. K. Demand Side Management of a Run-of-Mine Ore Milling Circuit. **Control Engineering Practice**. v. 21, p. 759-768, 2013.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade Para Engenheiros**, 4.ed., LTC, Rio de Janeiro, 2003.

MUNIZ, L. A. R. **Controle preditivo adaptativo aplicado a um reator de pirólise operando em regime semi-batelada**. Tese (Doutorado em Ciências da Engenharia Química). Departamento de Engenharia Química e Engenharia de Alimentos, Universidade Federal de Santa Catarina, 2014.

NAIDOO, M. A. **Nonlinear control with state estimation and power optimization for a rom ore milling circuit**. Master Engineering (Electronic Engineering). University of Pretoria, 2014.

NGUYEN, D.; GADHAMSHETTY, V.; NITAYAVARDHANA, S.; KHANAL, S. K.; Automatic process control in anaerobic digestion technology: A critical review. **Bioresource Technology**. v. 193, p. 513-522, 2015.

OLIVIER, L. E. **Peripheral control tools for a run-of-mine ore milling circuit**. Master Engineering (Electronic Engineering). University of Pretoria, 2011.

OLIVIER, L. E.; CRAIG, I. K. Parameter mismatch detection in a Run-of-Mine Ore milling circuit under Model Predictive Control. **Preprints of the 18th IFAC World Congress**. Milano (Italy), 2011.

OLIVIER, L.E; HAUNG, B.; CRAIG, L.K. Dual particle filters for state and parameter estimation with application to a run-of-mine ore mill. **Journal of Process Control**. v. 22, p. 710-717, 2012.

PRETT, D. M.; GARCÍA, C. E. **Fundamental process control**. Boston: Butterworths, 1988. Disponível em: <<https://books.google.com.br/books?id=4eAgBQAAQBAJ&pg=PA124&dq=Fundamental+process+control&hl=pt-BR&sa=X&ved=0ahUKEwiErPXfiJvMAhXCipAKHX8zC0gQ6AEINDAA#v=onepage&q=Fundamental%20process%20control&f=false>> Acesso em: 19 abr. 2016.

QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control Engineering Practice**. v.11, p. 733-764, 2003.

RASOULIAN, S.; RICARDEZ-SANDOVAL, L. A. Stochastic nonlinear model predictive control applied to a thin film deposition process under uncertainty, **Chemical Engineering Science**, v. 140, p. 90-103, 2016.

RAWLINGS, J.; MAYNE, D. **Model Predictive Control: Theory and Design**. 2. ed. Madison, Wisconsin: Nob Hill Publishing, LLC, 2012.

REIF, K.; GUNTHER, S.; YAZ, E.; UNBEHAUEN, R. Stochastic stability of the discrete-time extended Kalman filter, **IEEE Transactions on Automatic Control**, v. 44(4), p. 714-728, 1999.

SANTORO, B. F. **Controle Preditivo de horizonte infinito para sistemas integradores e com tempo morto**. Dissertação (Mestrado em Engenharia). Escola Politécnica, Universidade de São Paulo, 2011.

SCHAGEN, K. M.; KIETVELD, L. C.; B. R.; KRAMER, O. J. I. Model-based operational constraints for fluidized bed crystallization, **Water Research**, v. 42, p. 327-337, 2008.

SCHWAAB, M.; PINTO, J. C. **Análise de Dados Experimentais: I Fundamentos de Estatística e Estimação de Parâmetros**, E-papers, Rio de Janeiro, 2007.

SEBORG, D. E.; EDGAR, T. F.; MELLICHAMP, D. A. **Process Dynamics and Control**. 2. ed. Danvers, MA: John Wiley & Sons, 2003.

SHAO, X.; HUANG, B.; LEE, J. M. Constrained Bayesian state estimation – A comparative study and a new particle filter based approach, **Journal of Process Control**, v. 20, p. 143-157, 2010.

SHIMADA, K.; NISHIDA, T. Particle Filter - Model Predictive Control of Quadcopters. **International Conference on Advanced Mechatronic Systems**, Kumanoto, Japan, 2015.

SILVA NETO, A. J.; BECCENERI, J. C. (Ed.). **Técnicas de inteligência computacional inspiradas na natureza: aplicação em problemas inversos em transferência radiativa**. 2ª edição, São Carlos, SP: SBMAC – Sociedade Brasileira de Matemática Aplicada e Computacional, v. 41, 2012.

SILVA, G. D. C. **Estudo de um controlador preditivo não linear multivariável baseado em redes neurais**. Dissertação (Mestrado em Ciências), Programa de Tecnologia de Processos Químicos e Bioquímicos, Universidade Federal do Rio de Janeiro, 2014.

SILVA, W. B. **Aplicação de filtros de partículas para assimilação de dados em problemas de fronteira móvel**. Tese (Doutorado em Engenharia Mecânica). COPPE, Universidade Federal do Rio de Janeiro, 2012.

SKOGESTAD, S. Plantwide control: the search for the self-optimizing control structure, **Journal of Process Control**, v. 10, p. 487-507, 2000.

SOARES, P. O. **Um problema inverso em dois passos para estimação de perfis de temperatura na atmosfera com nuvens a partir de medidas de radiação feitas por satélite**. Tese (Doutorado em Modelagem Computacional), Instituto Politécnico, Universidade do Estado do Rio de Janeiro, 2013.

STAHL, D.; HAUTH, J. Particle filter - model predictive control. **Systems & Control Letters**, v. 60, p. 632–643, 2011.

TEIXEIRA, B. O. S.; TÔRRES, L. A. B.; Filtragem de Kalman com restrições para sistemas não-lineares: revisão e novos resultados, **Revista Controle & Automação**, v. 21, p. 127-146, 2010.

TONEL, G. **Avaliação dos Estimadores EKF, CEKF e MHE para Aplicações em Linha em Processos**. Dissertação (Mestrado em Engenharia Química). Escola de Engenharia, Universidade Federal do Rio Grande do Sul, 2008.

UNGARALA, S.; LI, K.; CHEN, Z. Constrained bayesian state estimation using a cell Filter, **Ind. Eng. Chem. Res.**, v. 47, p. 7312-7322, 2008.

VAN DER WESTHUIZEN, A.; POWELL, M. S. Milling curves as a tool for characterizing SAG mill performance, **In: Proceedings of SAG 2006**, p. 217-232, 2006.

WANG, L. **Model Predictive Control System Design and Implementation using MATLAB**. Natick, MA: Springer, 2008.

XAVIER, J. E. S. C. **Aplicação do Filtro de Kalman na correcção de dados provenientes de um sistema de Localização baseado em RFID**. Mestrado (Engenharia Eletrotécnica e de Computadores), Faculdade de Engenharia, Universidade do Porto, 2011.

ZHAO, Z.; HUANG, B.; LIU, F. A particle filter based on a constrained sampling method for state estimation, **Information Fusion (FUSION), 15th International Conference on**, p. 816-823, 2012.

ZHAO, Z.; HUANG, B.; LIU, F. Bayesian method for state estimation of batch process with missing data, **Computers and Chemical Engineering**, v. 53, p. 14-24, 2013.

ZHAO, Z.; HUANG, B.; LIU, F. Constrained particle filtering methods for state estimation of nonlinear process, **Aiche journal**, vol. 60, p.2072-2082, 2014.

ZHAO, Z.; SHAO, X.; HUANG, B.; LIU, F. On-line estimation of glucose and biomass concentration in batch fermentation process using particle filter with constraint, **Asia Pac. J. Chem. Eng.**, v. 7, p. 678-686, 2012.