

Julio Paez de Castro Oliveira

**Otimização em tempo real aplicada em um  
sistema experimental de Gas Lift**

São Paulo

2022



Julio Paez de Castro Oliveira

# **Otimização em tempo real aplicada em um sistema experimental de Gas Lift**

## **Versão Corrigida**

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Mestre em Ciências.

Área de Concentração: Engenharia Química.

Orientador: Prof. Dr. Galo Antonio Carrillo Le Roux.

Coorientador: Dr. José Otávio Assumpção Matias

São Paulo

2022

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

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

São Paulo, 14 de novembro de 2022

Assinatura do autor:



Assinatura do orientador:



#### Catálogo-na-publicação

Paez de Castro Oliveira, Julio  
Otimização em tempo real aplicada em um sistema experimental de Gas Lift / J. Paez de Castro Oliveira -- versão corr. -- São Paulo, 2022.  
94 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Química.

1.Otimização 2.Não-linearidade 3.Estimadores online 4.Otimização em tempo real I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Química II.t.





# Agradecimentos

Toda jornada por mais solitária que possa parecer conta com a presença de diversas pessoas que participam diretamente ou indiretamente desse processo, nesta jornada chamada mestrado não foi diferente. Muitas pessoas foram e vieram durante esse período, mas todas elas contribuíram para que este trabalho fosse possível e, por isso, agradeço a todos que encontrei pelo caminho. Claro que em toda história existem pessoas mais importantes e não poderia faltar um agradecimento mais personalizado.

Primeiramente agradeço aos meus colegas, pelas discussões, aprendizados, cafézinhos e pelos muitos momentos em que compartilhamos nossas dores e alegrias. Em especial aos colegas dos grupos de trabalho que participei e que me ajudaram tanto nessa jornada.

Agradeço também a todos os professores do mestrado pelos ensinamentos, muitos que já me aturaram na graduação e tiveram que sofrer mais um pouquinho. Com um agradecimento especial ao professor Galo Le Roux que me introduziu ao mundo de análise de sistemas em engenharia química pelo qual me apaixonei, pela orientação nesses anos de estudo e pela inspiração na busca do conhecimento. Também ao professor Johannes Jäsche pelo acolhimento e supervisão durante minha estadia na Noruega.

Ao projeto SUBPRO e a universidade norueguesa NTNU pela oportunidade de aplicar os estudos desta dissertação em seus equipamentos e a todas as instituições que apoiam financeiramente aqueles que acreditam, trabalham e incentivam a pesquisa em busca de um futuro mais brilhante.

Um agradecimento especial ao meu coorientador e colega José Otávio que me ajudou em diversos momentos, tanto para entender conceitos e teorias, implementar códigos, ler e reler diversas vezes esta dissertação (foi mal) como pelo apoio, paciência e ensinamentos. Esta dissertação não teria sido a mesma sem suas contribuições.

Enfim, gostaria de agradecer minha família pelo imenso suporte durante toda essa jornada minha vó, minha tias, minhas primas e primos. Especialmente a tia Moema e tia Gertrudes pelos bons momentos e também pelo abrigo e comida quando necessitava ir para a USP e a minha vó Iracema por sempre me fazer rir e sentir melhor. Aos meus irmãos Ariane, Gabriel e Luiz Gustavo por sempre estarem presentes compartilhando os bons momentos da vida e aos meus pais Eufemia e Vicente por todos os apoios possíveis que alguém poderia desejar, essa jornada não teria acontecido sem o apoio de vocês. Por último, gostaria de agradecer a Renata sua dedicação e resiliência me inspiraram a continuar lutando não importando as dificuldades que pudessem aparecer pela frente e seu apoio foi sem dúvida essencial para concluir essa jornada, não poderia desejar alguém melhor para estar ao meu lado.





*"Uneasy lies the head that wears a crown"*  
*(William Shakespeare - 'Henrique IV')*



# Resumo

A otimização em tempo real (RTO - Real-time Optimization) é um procedimento que permite aumentar a lucratividade em operações industriais pela busca das condições ótimas de operação considerando aspectos econômicos e de processo durante a produção. Desde a década de 70, diversos modos de implementação dessa ferramenta foram propostos, sendo o método de dois passos por adaptação de parâmetros do modelo (MPA - Model Parameter Adaptation) um dos mais utilizados industrialmente. Apesar disso, a MPA utiliza informações em estado estacionário para a resolução da RTO e isso pode trazer desvantagens na aplicação e na busca do ponto ótimo em sistemas dinâmicos. Recentemente a otimização em tempo real por adaptação persistente de parâmetros (ROPA - Real-time Optimization with Persistent Adaptation) foi proposta como uma nova metodologia de RTO para contornar essas desvantagens. Utilizando uma abordagem híbrida que considera informações dos estados estacionário e transiente, este método apresentou resultados promissores, porém esses resultados foram apenas em sistemas simulados, sem a aplicação em sistemas físicos. Além disso há poucos estudos sobre as diferentes abordagens relacionadas a aplicação dessa metodologia, como o uso de diferente estimadores. Visando complementar o desenvolvimento da ROPA, um equipamento experimental que simula a operação de *Gas Lift*, extração por injeção de gás comum em plataformas de petróleo *offshore*, foi utilizado para aplicar a ROPA. O experimento teve por objetivo avaliar o comportamento da ROPA em um sistema real e comparar seus resultados em relação à MPA e em relação a si próprio com o uso de dois estimadores diferentes, o filtro de Kalman estendido (EKF - Extended Kalman Filter), único estimador utilizado na ROPA até o momento, e o estimador de horizonte móvel (MHE - Moving Horizon Estimation). Para isto foi feita a modelagem do experimento, já que a ROPA e a MPA são baseadas no uso de modelos, e avaliada a adequação do modelo ao equipamento experimental. A MPA e a ROPA (utilizando o EKF como estimador de parâmetros) foram implementadas, utilizando o modelo desenvolvido, e os resultados da otimização comparados. Na comparação a ROPA teve um lucro de 1% maior em relação à MPA e teve boa performance na otimização durante períodos transientes. Em seguida seria feito a comparação do EKF e do MHE na ROPA, porém foi feito um estudo anterior para verificar a estimação do MHE no modelo proposto. Nesse estudo avaliou-se a influência de uma parte do equacionamento do MHE chamado de custo de chegada (*arrival cost*) e verificou-se que esse termo é importante para obter uma estimação adequada dos parâmetros do modelo. Após o estudo foi realizada a comparação da ROPA com o EKF e com o MHE e a ROPA-EKF teve o lucro 1% maior em relação à ROPA-MHE mas ambos tiveram performances semelhantes na estimação. Em conclusão, a ROPA foi bem sucedida quando aplicada em um equipamento físico, a ROPA teve resultados melhores quando comparado à MPA, principalmente em momentos não estacionários, e a ROPA mostrou-se flexível no uso de outros estimadores.

Palavras-chaves: Otimização, Não-linearidade, Estimadores online, Otimização em tempo real.

# Abstract

Real-time Optimization (RTO) is a production optimization technique that aims at improving plant economic performance in real-time. Many proposals of this technique have been made, being the two step RTO known as model parameter adaptation (MPA) the most traditional. Although being widely used in industrial application, the MPA uses stationary process information to perform the optimization and is not appropriated for dynamic systems. Recently a real time optimization with persistent adaptation (ROPA) has been proposed as a new RTO approach to handle and optimize dynamic systems. With a hybrid approach that uses stationary and transient information this method has shown promising results, but more studies are still necessary to support those results. The absence of a real system application, only implementation in simulated environments, and the lack of studies in different approaches regarding this method are some of the issues that still needs to be discussed. To contribute to the development of ROPA, this work presents an implementation of ROPA on an experimental rig that emulates a subsea oil extraction by Gas Lift. This experiment will evaluate ROPA performance in an real environment and compare the results with MPA. In order to apply ROPA two different online estimators are selected, the extended Kalman filter (EKF) and the moving horizon estimation (MHE). This work begins by modelling the experiment, since MPA and ROPA are model based, then MPA and ROPA-EKF are implemented and compared. Finally, ROPA-MHE is implemented and compared with ROPA-EKF. In order to implement ROPA-MHE a study on the arrival cost, a penalty term of MHE, was performed and it was verified the importance of this term on obtaining accurate estimations. The results obtained in this work have shown that ROPA-EKF had a better performance than MPA, specially in transient states, and ROPA-EKF and ROPA-MHE had similar performance.

**Keywords:** Optimization, Non Linearity, Online estimation, Real-time Optimization.



# Lista de ilustrações

Figura 1 – Hierarquia de decisão de uma planta (Adaptado de DARBY et al.2011).	20
Figura 2 – Comparação MPA e ROPA (Adaptado de Matias,Le Roux 2018).	21
Figura 3 – Figura ilustrativa da defasagem causada pela detecção do estado estacionário.	32
Figura 4 – Ilustração da estimação por horizonte móvel mostrando a representação de 2 janelas. (Adaptado de Hashemian e Armaou 2015).	37
Figura 5 – Representação do efeito da injeção de gás sobre a produção de líquido.	42
Figura 6 – Representação de <i>Gas Lift</i> em poço de extração offshore.	42
Figura 7 – Esquema do experimento que simula a operação de <i>Gas Lift</i> .	43
Figura 8 – Esquema simplificado do experimento indicando as variáveis utilizadas na modelagem.	45
Figura 9 – Não linearidade da vazão de líquido em relação a injeção de ar.	48
Figura 10 – Análise dos dados da planta em relação ao modelo ajustado por minimização quadrática.	49
Figura 11 – Histograma e estudo de identificabilidade para 100 experimentos independentes de estimação de parâmetros.	52
Figura 12 – Validação do modelo de estado estacionário.	54
Figura 13 – Comparação da função objetivo e do ponto ótimo de injeção de ar para os três cenários estudados utilizando a MPA.	56
Figura 14 – Vazão injeção de ar utilizados no estudo de ponto ótimo para os três cenários estudados.	57
Figura 15 – Estudo do ponto ótimo de cada cenário pelo cálculo da função objetivo em diferentes vazões de injeção de ar.	58
Figura 16 – Perfil de distúrbio para a comparação MPA e ROPA-EKF.	59
Figura 17 – Detecção de Estado Estacionário. A variável Flag indica se durante a etapa de detecção de estado estacionário o sistema foi considerado estacionario (Sim) ou não estacionário (Não).	60
Figura 18 – Comparação da estimativa dos parâmetros da válvula e do reservatório para os métodos ROPA-EKF e MPA.	61
Figura 19 – Comparação do ponto ótimo de injeção de ar entre ROPA-EKF e MPA.	62
Figura 20 – Comparação do lucro considerando a ROPA-EKF, a MPA e o valor fixo.	62
Figura 21 – Diferença de lucro entre as RTO e o experimento fixo.	63
Figura 22 – Estimação MHE para o experimento 1: Parâmetros, Pressão, Vazão.	66
Figura 23 – Perfil de distúrbio para comparação entre ROPA utilizando o EKF e o MHE.	68

Figura 24 – Perfil dos parâmetros estimados para o ROPA utilizando o MHE e o EKF. . . . .	69
Figura 25 – Perfil de pressão do topo obtida com os medidores de pressão localizados no topo do experimento. . . . .	70
Figura 26 – Comparação do perfil de injeção de ar entre o ROPA-EKF e o ROPA-MHE. . . . .	70
Figura 27 – Comparação de lucro entre o ROPA-EKF, ROPA-MHE e a injeção de ar fixa . . . . .	71
Figura 28 – Comparação do lucro acumulado entre a ROPA-MHE e ROPA-EKF. . . . .	72
Figura 29 – Comparação do lucro acumulado em porcentagem entre a ROPA-EKF e MPA. A linha azul é relacionada a outra análise realizada pelos autores e deve ser desconsiderada na interpretação dessa imagem. (Adaptado de Matias et al 2022) . . . . .	72
Figura 30 – Dados para validação do modelo. . . . .	86
Figura 31 – Foto do equipamento completo utilizado para simulação da operação de <i>Gas Lift</i> . . . . .	87
Figura 32 – Foto dos controladores. . . . .	88
Figura 33 – Foto do bomba e suas tubulações. . . . .	88
Figura 34 – Estimação MHE para o experimento 2: Parâmetros, Pressão, Vazão. . . . .	91
Figura 35 – Estimação MHE para o experimento 3: Parâmetros, Pressão, Vazão. . . . .	92



# Lista de tabelas

Tabela 1 – Média de lucro acumulado de 4 experimentos idênticos e independentes	64
Tabela 2 – Parâmetros do modelo a serem estimados utilizados nas simulações . .	65
Tabela 3 – Média e desvio padrão para os últimos 70 pontos da análise da estimação de parâmetros pelo MHE com ou sem o custo de chegada . . . . .	67
Tabela 4 – Teste de validação . . . . .	85



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>19</b>
1.1	Otimização em tempo real	19
1.2	Otimização em tempo real - Nova perspectiva	21
1.3	Objetivos	22
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>23</b>
2.1	Uso de medidas no estado transiente para acelerar a otimização	23
2.2	Estimadores dinâmicos <i>online</i>	26
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>29</b>
3.1	<b>Adaptação de parâmetros do modelo (MPA)</b>	<b>29</b>
3.1.1	Modelo	29
3.1.2	Detecção de estado estacionário	29
3.1.3	Estimação de parâmetros do modelo	30
3.1.4	Otimização Econômica	31
3.2	<b>Otimização em tempo real com adaptação persistente de parâmetros (ROPA)</b>	<b>32</b>
3.2.1	Modelo	33
3.2.2	Estimadores dinâmicos	33
3.2.2.1	Filtro de Kalman estendido	34
3.2.2.2	Estimador de horizonte móvel	36
<b>4</b>	<b>ESTUDO DE CASO</b>	<b>41</b>
4.1	<b>Descrição do processo</b>	<b>41</b>
4.2	<b>Modelo do equipamento experimental</b>	<b>44</b>
4.2.1	Modelo em estado estacionário	44
4.2.2	Modelo em estado transiente	50
4.3	<b>Estimação dos parâmetros do modelo</b>	<b>50</b>
4.4	<b>Otimização</b>	<b>52</b>
4.5	<b>Resultados</b>	<b>53</b>
4.5.1	Validação do modelo	53
4.5.2	Análise RTO MPA	55
4.6	<b>Comparação MPA e ROPA-EKF</b>	<b>59</b>
4.6.1	Resultados da comparação entre MPA e ROPA-EKF	62
4.6.1.1	Análise do lucro da MPA e da ROPA no equipamento experimental	62

4.6.1.2	Análise da média do lucro acumulado de 4 experimentos independentes para cada um dos métodos . . . . .	64
4.6.2	Discussão dos resultados da comparação entre MPA e ROPA-EKF . . . . .	64
<b>4.7</b>	<b>Avaliação do custo de chegada do MHE . . . . .</b>	<b>65</b>
<b>4.8</b>	<b>Comparação ROPA-MHE e ROPA-EKF . . . . .</b>	<b>68</b>
4.8.1	Resultados da comparação entre ROPA-MHE e ROPA-EKF . . . . .	69
4.8.2	Discussão dos resultados da comparação entre ROPA-MHE e ROPA-EKF. . .	71
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>75</b>
<b>6</b>	<b>SUGESTÕES PARA ESTUDOS FUTUROS . . . . .</b>	<b>77</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>79</b>
	 <b>APÊNDICES</b>	 <b>83</b>
	<b>APÊNDICE A – DADOS DE VALIDAÇÃO DO MODELO . . . . .</b>	<b>85</b>
	<b>APÊNDICE B – EQUIPAMENTO EXPERIMENTAL E DESCRIÇÃO DO PROBLEMA DA BOMBA . . . . .</b>	<b>87</b>
	<b>APÊNDICE C – ESTUDO DE CASO MHE: OUTROS CENÁRIOS ESTUDADOS . . . . .</b>	<b>91</b>

# 1 Introdução

## 1.1 Otimização em tempo real

A Otimização em Tempo Real (RTO - Real Time Optimization) é utilizada em indústrias de forma a aumentar a sua lucratividade por meio da busca contínua de condições operacionais que otimizem a produção. Essa técnica permite avaliar a condição ótima de operação em sistemas considerando mudanças durante o processo, como a variação da composição de componentes, de custo de matérias-primas e de preço de produtos.

Atualmente a RTO faz parte de uma das camadas da hierarquia de decisão de uma planta (DARBY et al., 2011), representada pela Figura 1. As outras camadas são de planejamento (*Planning*), programação de atividades (*Scheduling*), controle multivariável, controle regulatório.

A primeira camada, denominada planejamento, é responsável pela determinação dos objetivos de produção levando em consideração a economia e o mercado. A camada de programação de atividades tem por função realizar o cronograma de atividades de forma a atingir os objetivos propostos.

Em seguida, a camada de RTO traduz as decisões da camada de programação de atividades em objetivos operacionais determinados por *setpoints* de algumas variáveis chave do processo. Apesar de estar relacionada ao processo, tal camada não manipula nenhuma variável (HUANG; HARINATH; BIEGLER, 2011), sendo isso realizado pelas camadas de controladores.

O controlador multivariável leva em consideração as variáveis do processo e permite manipular o comportamento do sistema considerando as mudanças nas restrições ativas do processo. Isso garante transições suaves e melhores respostas do sistema sem que suas restrições sejam violadas, geralmente é utilizado um controlador preditivo multivariável. Por fim o controle regulatório é composto por controladores mais simples, como o PID, que implementam o *setpoint* e auxiliam na estabilização da planta.

A RTO é uma ferramenta baseada na utilização de modelos para otimização das condições de operação da planta. O método clássico de RTO é denominado de adaptação de parâmetros do modelo (MPA - *Model Parameter Adaptation*) (CHEN; JOSEPH, 1987). A MPA consiste em um ciclo de cinco etapas que permitem determinar e implementar a condição ótima de operação (DARBY et al., 2011; NAYSMITH; DOUGLAS, 1995). As etapas realizadas são: detecção de estado estacionário, reconciliação de dados e detecção de erros grosseiros, estimação de parâmetros do modelo, otimização econômica e integração da solução com controlador. Após implementar a solução, o MPA volta a etapa de detecção



Figura 1 – Hierarquia de decisão de uma planta (Adaptado de DARBY et al.2011).

de estado estacionário e um novo ciclo se inicia quando o estado estacionário for detectado novamente. As cinco etapas de um ciclo são descritas a seguir:

- Detecção de estado estacionário: Para aplicação da RTO clássica é necessário que a planta esteja em estado estacionário, pois é utilizado um modelo de estado estacionário nas etapas de estimação, reconciliação de dados e otimização. Assim são utilizados métodos estatísticos que analisam dados da planta e permitem determinar se o processo está em estado estacionário.
- Detecção de erros e reconciliação de dados: As medidas dos dados de processo estão sujeitas a erros, tanto sistemáticos como aleatórios. Se estes erros não forem tratados, irão se propagar afetando a otimização da planta. Para isso, a reconciliação de dados faz uso de um modelo do processo e obtém estimativas das variáveis medidas pelo ajuste dos dados do modelo em relação às medições.
- Estimação de parâmetros do modelo: Esta etapa visa a estimação de alguns parâmetros do modelo de forma a minimizar a diferença entre as predições do modelo e as medidas da planta para representação mais real do processo.
- Otimização Econômica: Determinação do ponto operacional que melhor satisfaz o critério de desempenho econômico do processo em questão, sendo utilizado um algoritmo de programação não-linear para a maximização de uma função objetivo que descreve a lucratividade (ou custo) associado ao processo dentro de uma região de operação limitada por restrições do processo.
- Integração da solução com o controlador da planta: O resultado da otimização é enviado para o controlador da planta que implementa essa solução e a mantém dentro dos limites operacionais.

Apesar de muito utilizada industrialmente, essa abordagem pode não ser apropriada ou de difícil implementação em alguns processos industriais. Dificuldades como a espera

para o processo atingir o estado estacionário, o uso de modelos de estado estacionário para representar sistemas que são fundamentalmente dinâmicos e o escopo da RTO em processos de múltiplas unidades de uma planta são alguns dos problemas enfrentados pela metodologia clássica. Tais dificuldades são descritas por Friedman (1995), Darby et al. (2011).

## 1.2 Otimização em tempo real - Nova perspectiva

Para lidar com esses problemas, diversos métodos alternativos ao método clássico foram propostos, sendo o uso de medidas em estado transiente uma tendência na questão da estacionariedade. Um dos métodos mais recentes é a otimização em tempo real com adaptação persistente de parâmetros (ROPA - Real-time Optimization with Persistent Adaptation) e sua versão assíncrona (asROPA), ambos propostos por Matias e Le Roux (2018, 2020), respectivamente. A Figura 2 compara a estrutura de implementação da RTO clássica com a da ROPA.

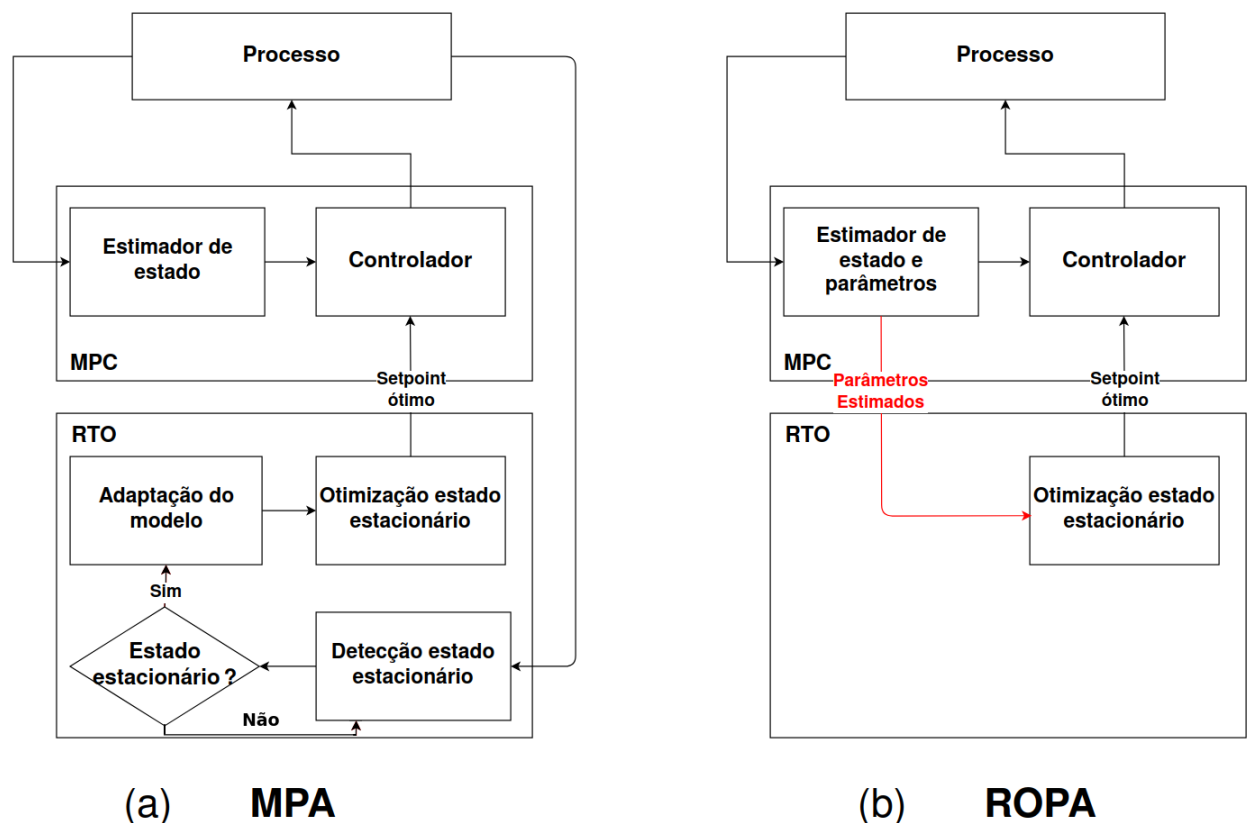


Figura 2 – Comparação MPA e ROPA (Adaptado de Matias, Le Roux 2018).

A ROPA propõe alterações no método de estimação utilizando-se de estimadores *online* e modelos dinâmicos para a estimativa de parâmetros a partir de dados transientes. Dessa forma não se faz necessário a espera por um estado estacionário, pois os parâmetros utilizados na resolução da otimização serão estimados continuamente, independentemente

se o sistema está em estado estacionário ou transiente. Além disso, o uso de modelos dinâmicos permite representar processos que são fundamentalmente dinâmicos.

No entanto o uso de modelos dinâmicos está associado somente a etapa de estimação de parâmetros do modelo, a otimização continua sendo realizada pelo uso de modelos estacionários como na MPA. Outra particularidade da ROPA é que como o sistema não necessita identificar o estado estacionário, um parâmetro denominado  $\Delta T^{ROPA}$  é definido para determinar o intervalo entre o fim de um ciclo da ROPA e o início de um novo ciclo.

Apesar dos resultados promissores apresentados pelos autores, ainda são necessários mais estudos de caso, o uso de diferentes estimadores *online*, verificando seus efeitos na otimização, e a validação da ROPA em um sistema físico para consolidar esses resultados.

### 1.3 Objetivos

Baseado na RTO por adaptação de parâmetros do modelo proposta na década de 70, a ROPA é uma nova abordagem que busca contornar problemas associados à implementação em escala industrial e melhorar o desempenho. Apesar disso, esse método tem apenas aplicações em simulações até o momento. Assim, esta dissertação tem por objetivo realizar a primeira aplicação em um sistema físico ao implementar a ROPA em um equipamento experimental que simula a extração de petróleo pelo método de *Gas Lift*, descrito na seção 4.1, e comparar os resultados com a MPA, método já usado industrialmente, aplicada no mesmo equipamento.

Também é estudada a questão do estimador *online* a ser utilizado para estimação dos parâmetros no estado transiente. Existem diversos algoritmos que podem ser selecionados para essa operação. Apesar disso, até o momento, a ROPA só tem aplicações utilizando o filtro de Kalman estendido. O uso de outros estimadores *online* pode reduzir o tempo computacional, melhorar a estimação de parâmetros e, por consequência, a otimização econômica, e aumentar a flexibilidade da ROPA em sistemas que não tenham boa estimação a um determinado estimador. Assim nesta dissertação foram selecionados dois estimadores *online* a serem implementados e avaliados na ROPA, o filtro de Kalman estendido, que é o método já utilizado pela ROPA, e o estimador de horizonte móvel.

Em conclusão, há um esforço contínuo no desenvolvimento desta área de estudo, pois pode trazer elevados lucros para a produção industrial. Esta dissertação tem por motivação agregar no desenvolvimento da RTO e, principalmente, da metodologia ROPA.



## 2 Revisão Bibliográfica

### 2.1 Uso de medidas no estado transiente para acelerar a otimização

A ROPA é um método recente que busca utilizar medidas em estado transiente para adaptar os parâmetros de um modelo dinâmico e assim agilizar o processo de otimização em tempo real. Apesar disso, o uso de medidas transientes visando acelerar a otimização em produção não é algo novo, mas que já vem sendo investigada desde a década de 70.

Os primeiros estudos na área (SAWARAGI et al., 1971; BAMBERGER; ISERMANN, 1978) usaram medidas transientes para acelerar a otimização em produção. Nestes trabalhos estimam os parâmetros do estado dinâmico com o uso de modelos Hammerstein, que representam a dinâmica por meio de uma função de transferência linear e a parte estática por funções não lineares da entrada e da saída, e calculam os gradientes em estado estacionário com esses parâmetros. A otimização do problema é então realizada por um algoritmo de busca por gradiente. Apesar de ter sua aplicação bem sucedida em algumas plantas piloto (por exemplo circulação de água de resfriamento em usina termelétrica (BAMBERGER; ISERMANN, 1978), coluna de destilação (SAWARAGI et al., 1971), e reator de leito fixo (LEE; LEE, 1985)), o método proposto não considera restrições na otimização.

Como a RTO é resolvida como um problema de otimização é natural considerar restrições, porém depender da abordagem que necessita da espera do estado estacionário diminui consideravelmente a frequência das otimizações. Por isso definir novas estratégias de incorporação de medidas transientes ainda era interessante. Desde então grande parte das tentativas de obter maiores velocidades no processo de otimização, no contexto de otimização em tempo real, partiram do princípio descrito por Engell (2007) em que um passo na direção correta é melhor do que esperar pelo estado estacionário do sistema.

Com isso alguns métodos de modificação da MPA foram propostos para acelerar a espera pelo estado estacionário. Em Besl et al. (1998), os autores realizavam a estimação do modelo quando a planta encontrava-se em estado estacionário, porém a otimização era realizada após um certo intervalo de tempo fixo, independentemente da planta estar em estado estacionário. De maneira similar, Prior e Lopez (1999) estimavam assincronamente seções individuais quando elas estavam em estado estacionário e a otimização era feita em um intervalo de tempo fixo utilizando os últimos parâmetros estimados. Sequeira et al. (2002) propuseram um método chamado de evolução em tempo real (*Real-Time Evolution* - RTE). No RTE, informações em estado estacionário são utilizadas apenas para a reconciliação de dados e estimação de modelos, ou seja, não realiza a otimização em

estado estacionário. O método consiste em um mecanismo de busca que, após a ocorrência de distúrbios, já começa a realizar pequenos ajustes no ponto de operação de modo a obter uma melhora na função objetivo. Assim o ponto a ser otimizado já vai se aproximando do valor ótimo de operação antes mesmo de identificar o estado estacionário. Quando o sistema atingir a estacionariedade o ponto obtido pela busca já estará muito próximo do ponto ótimo no estado estacionário. Esse mecanismo de busca é similar ao EVOP (BOX, 1957), mas baseado no modelo em estado estacionário ao invés de perturbações na planta.

Apesar dos métodos mencionados apresentarem grandes benefícios, eles só podem ser aplicados em sistemas quase estacionários já que negligenciam a dinâmica. Além disso, a falta de frequência na atualização do modelo pela estimação de parâmetros pode reduzir a capacidade de previsão destes métodos. Essa questão foi parcialmente resolvida por Rodrigues et al. (2018), em que propuseram uma implementação acelerada da RTO de dois passos. Neste trabalho consideram processos que possam ser separados em estados rápidos e estados lentos, sendo que a dinâmica do estado rápido deve ser desconhecida e a do lento conhecida. Nos estados rápidos utilizam filtros convolucionais para estimar a taxa de dinâmica a partir das medidas transientes e com um controle retroalimentar (*feedback control*) utilizam esta taxa de dinâmica para obter o estado estacionário do sistema mais rapidamente.

Apesar de obter uma aceleração na aplicação da RTO, existem algumas desvantagens nesse método como a necessidade das dinâmicas do sistema serem caracterizadas como rápidas e lentas, a parte desconhecida da dinâmica ser referente apenas ao estado rápido e a performance do método ser muito sensível ao ruído por ser baseado no uso de dados da entrada e da saída para o cálculo da taxa. Assim para contornar essas dificuldades, é natural pensar em utilizar modelos dinâmicos para representar a dinâmica do sistema completo, como feito na ROPA e na otimização em tempo real dinâmica (*dynamic real-time optimization - DRTO*).

A DRTO, assim como a ROPA e a MPA, é uma RTO baseada no uso de modelos e realizada em dois passos, estimação de parâmetros e otimização de uma função objetivo, porém é utilizado um modelo dinâmico nestas duas etapas. A DRTO tem uma estrutura de implementação muito parecida à da ROPA, apresentada na Figura 2. Matias et al. (2022) compararam a performance da DRTO, da ROPA e da MPA e obtiveram que a ROPA e a DRTO tiveram resultados semelhantes e ambas foram superiores em relação a MPA para o sistema estudado.

O principal desafio neste tipo de estratégia é obter um modelo dinâmico preciso. Delou et al. (2021) propuseram o uso de uma estrutura de modelagem Hammerstein para representar a dinâmica do sistema. Essa estrutura aproveita do modelo em estado estacionário e adiciona dinâmicas por meio de um modelo linear autoregressivo (*linear autoregressive model - ARX*) obtido a partir de dados da planta.

Outras abordagens no contexto da ROPA também foram propostas. Valluru and Patwardhan (2019) e Santos et al. (2021) propuseram o uso de estimadores dinâmicos para estimar o modelo da camada de controle preditivo (MPC) visando evitar diferença nos modelos durante a integração das camadas de RTO e MPC. Shamaki and Odloak (2020) combinaram a ROPA com um controlador preditivo de horizonte infinito (*infinite horizon zone control* MPC). Curvelo et al. (2021) estudaram a performance da ROPA quando aplicada a diferentes padrões de estados transientes, como mudanças rápidas ou lentas no comportamento do sistema, e verificaram a melhor performance da ROPA na maioria dos padrões. Por último, Matias et al. (2020) propuseram estender o contexto da ROPA para otimização de uma planta utilizando a estimação assíncrona de parâmetros, essa abordagem foi explorada na introdução.

Além da ROPA, existem outras estratégias que buscam misturar as medidas transientes com a otimização em estado estacionário. François e Bovin (2013), Rodríguez-Blanco et al. (2017), Gao e Engell (2017) propuseram diferentes formas de obtenção dos modificadores aditivos nos métodos de adaptação por modificadores (*Modifiers-Adaptation Methods* - MA) com o uso de medidas transiente. O MA utiliza modificadores aditivos na função objetivo e restrições de modo que os pontos de Karush-Kuhn-Tucker (KKT) do modelo coincidam com os da planta (MARCHETTI; CHACHUAT; BONVIN, 2009) e assim contornando o problema de modelagens que não representam adequadamente o sistema (*plant-model mismatch*).

A diferença entre os trabalhos está na forma do uso das medidas transientes. François e Bovin (2013) utilizam uma técnica denominada *Neighbouring-Extremal* (NEC), que realiza aproximações lineares nas condições necessárias de otimalidade de primeira ordem e baseado nos desvios das saídas devido a distúrbios e incertezas calculam as entradas ótimas. No trabalho utilizam o NEC para estimar gradientes que são utilizados para calcular os modificadores aditivos da MA. Rodríguez-Blanco et al. (2017) propõem uma técnica em que utilizam os valores das medidas transientes de entrada e saída em um algoritmo recursivo de minimização quadrática estendida (RELS - recursive extended least squares algorithm) de modo a obter uma estimativa dos gradientes do processo e das restrições, esses gradientes são depois utilizados para calcular os modificadores aditivos da MA. Gao and Engell (2017) partem da ideia de que, próximo do estado estacionário, modelos dinâmicos podem ser aproximados por modelos dinâmicos lineares e propõem o uso de modelos ARX para estimar o próximo estado estacionário a partir de dados transientes.

Outra estratégia proposta é a de controle na busca de extremos (*Extremum-seeking control*), essa técnica busca pontos de operação que maximizam ou minimizam uma função objetivo sem o uso de um modelo do sistema. Ela consiste na adição de um sinal modulado ao valor do parâmetro que otimiza o sistema, de forma que o valor da função objetivo

sempre se aproxime do valor ótimo. A função objetiva deve ser concava para que esse método possa ser utilizado.

Dois trabalhos utilizaram esta técnica. O primeiro de Guay et al. (2005) utilizou redes neurais de funções de base radial (*Radial basis function neural networks*) para aproximar um sistema de um reator agitado não isotérmico contínuo em uma função contínua  $\pi(T)$ , em que  $T$  é a temperatura do sistema. Essa função representa o equilíbrio químico no reator e sua maximização indica que o sistema está em equilíbrio, que nesse caso também indica o estado estacionário do sistema. Aplicando o controle na busca de extremos é possível maximizar a função e obter o valor de  $T$ . Com esse valor obtém-se o gradiente de temperatura e implementa-se este gradiente no controlador de modo a obter o estado estacionário mais rapidamente. Krishnamoorthy et al. (2019) propuseram um esquema de busca de extremos baseado em identificar, usando as medidas transientes, um modelo dinâmico linear em torno do ponto de operação. Com isso uma aproximação do gradiente de estado estacionário é obtida e pode ser utilizada para levar o sistema ao seu ótimo.

Por último, Dirza et al. (2021) propuseram um método de RTO baseado em retroalimentação distribuída (*distributed feedback-based RTO methods*). Métodos de retroalimentação visam eliminar a necessidade de resolver problemas de otimização numéricos ao moverem o problema de otimização para a camada de controladores. No método proposto os autores utilizam de informações em estado transiente para estimar gradientes estacionários da planta. Esses gradientes, então, são utilizados para aproximar o gradiente do lagrangiano do problema de otimização estacionário. Por fim, os controladores manipulam a planta de tal forma que o gradiente do lagrangiano seja igual a zero, o que indica que o ótimo foi alcançado para um conjunto conhecido de restrições ativas.

## 2.2 Estimadores dinâmicos *online*

No caso da ROPA as informações em estado transiente são utilizadas por estimadores dinâmicos *online* para a estimação dos parâmetros do sistema. A estimação de estados em sistemas estáticos teve início com Thomas Bayes e a proposição do teorema de Bayes (1763). Posteriormente, Kalman (1960) desenvolveu um filtro recursivo no domínio do espaço e tempo, permitindo a estimação *online* de estados do sistema (ALEXANDER et al., 2020). Apesar desse grande avanço, o filtro de Kalman só podia ser aplicado em sistemas lineares. Ao longo dos anos diversas variações do filtro de Kalman foram propostas, principalmente focando na aplicação em sistemas dinâmicos.

O filtro de Kalman estendido (*Extended Kalman Filter* - EKF) (1962) é um método baseado no filtro de Kalman que utiliza de linearizações para permitir a aplicação das técnicas de estimação recursiva presentes no filtro de Kalman em modelos não lineares.

Isso torna o EKF um método eficiente computacionalmente, como o filtro de Kalman, mas por outro lado pode ter dificuldades em lidar com sistemas altamente não lineares e sua sintonia pode ser desafiadora (BIEGLER; YANG; FISCHER, 2015).

O EKF de posto reduzido (*reduced rank EKF* - rEFK) propõe mudanças na estrutura da fase de predição da covariância utilizando uma aproximação dessa predição baseada nos autovalores (PHAM; VERRON; ROUBAUD, 1998), isso melhora a estimação de estados e parâmetros em casos que eles não podem ser inferidos com precisão a partir de medidas das plantas.

Outro método baseado no filtro de Kalman é o *unscented Kalman Filter* (UKF) (2004) em que se aproxima a distribuição dos estados, ao invés do modelo não linear, por meio de *sigma points* que representam a verdadeira média e covariância das variáveis de estado, isso ajuda a mitigar os efeitos causados pela linearização do modelo especialmente na atualização da média e covariância. Esses são apenas alguns exemplos, porém existem diversos outros.

Diferentemente dos estimadores recursivos como o filtro de Kalman, também existem estimadores baseados em otimização. Entre eles o estimador de horizonte móvel (*Moving Horizon Estimation* - MHE) (1975) é o maior representante desse grupo. O MHE permite estimar um horizonte infinito de medidas ao separar o horizonte de medidas em dois, o horizonte recente e o passado. Sem essa segmentação a otimização se tornaria impossível de calcular, pois o sistema iria adquirir novas medidas e o horizonte de estimação iria aumentar até se tornar muito grande para ser resolvido.

No horizonte recente é feita a estimação dos estados por otimização considerando uma janela de tamanho fixo. As medidas contidas nessa janela são utilizadas para estimar os estados. Para o horizonte passado é feita uma aproximação chamada de custo de chegada (*arrival cost*) que estima o valor do estado logo antes de chegar ao horizonte recente. Esse custo de chegada pode ser interpretado como a informação *a priori* do sistema e seu valor será utilizado para obter o estado inicial da janela do horizonte recente. No surgimento de uma nova medida, esta é incluída na janela e a medida mais antiga excluída. A cada nova medida são realizados o cálculo do custo de chegada e a otimização da janela até que todo o horizonte de medidas seja contemplado (RAO; RAWLINGS, 2000).

Existem diversos modos de calcular o custo de chegada. Uma das maneiras é utilizar um esquema de filtro, já que o custo de chegada é baseado em medidas passadas, sendo que o estado *a posteriori* determinado por um filtro como o EKF (RAO; RAWLINGS, 2000) ou o UKF (QU; HAHN, 2009) é utilizado como valor do custo de chegada. Um problema é que isto pode introduzir oscilações na estimação dos estados, podendo ser utilizados esquemas de alisamento (*smoothing scheme*), como realizado por Lopez e Biegler (2012), para contornar esta questão (SCHEI, 2007).



## 3 Fundamentação Teórica

### 3.1 Adaptação de parâmetros do modelo (MPA)

A MPA, como mencionado, é composta de cinco etapas, porém dessas apenas a detecção de estado estacionário, a estimação de parâmetros do modelo e a otimização econômica serão comentadas. As etapas de detecção de erros e integração da solução com o controlador não serão comentadas na fundamentação teórica, pois podem variar de acordo com o processo a ser realizado ou equipamento a ser utilizado.

Por se tratar de uma técnica baseada no uso de modelos, uma breve descrição será adicionada explicando a formulação do modelo em estado estacionário para o uso da RTO. Em seguida, serão apresentadas as etapas mencionadas acima.

#### 3.1.1 Modelo

O modelo de estado estacionário é representado por:

$$\begin{aligned} 0 &= f(x, u, p) \\ y &= h(x, u, p) + v \end{aligned} \tag{3.1}$$

No qual  $x \in \mathbb{R}^{n_x}$  são as variáveis de estado do modelo,  $u \in \mathbb{R}^{n_u}$  são as variáveis manipuláveis do sistema,  $p \in \mathbb{R}^{n_p}$  são os parâmetros do modelo e  $y \in \mathbb{R}^{n_y}$  são as saídas do modelo.  $f$  e  $h$  são funções não lineares e  $v$  é um ruído gaussiano com média zero e variância constante  $R_p \in \mathbb{R}^{n_y, n_y}$ .

Os parâmetros  $p$  são divididos em dois tipos: parâmetros fixos, que não serão estimados, e parâmetros a serem estimados pela MPA. Para facilitar a compreensão das equações os parâmetros fixos serão omitidos.

#### 3.1.2 Detecção de estado estacionário

Existem diversos métodos propostos para a detecção em estado estacionário, entre eles o teste estatístico de R proposto por Cao e Rhineheart (1995), o método baseado em wavelet proposto por Jiang et al. (2003), o método de interpolação polinomial proposto por Le Roux et al. (2008). Entretanto, neste trabalho foi somente utilizado o teste estatístico de R pela simplicidade de implementação e pelo estudo feito por Matias et al. (2021) em que mostraram que o teste estatístico de R era o mais adequado para o equipamento experimental utilizado pelos autores, que é o mesmo desta dissertação.

A Equação 3.2 descreve o método.

$$\begin{aligned}
 z_{f,k} &= \lambda_1 z_k + (1 - \lambda_1) z_{f,k-1} \\
 \delta_{1,f,k}^2 &= \lambda_2 (z_k - z_{f,k-1})^2 + (1 - \lambda_2) \delta_{1,f,k-1}^2 \\
 \delta_{2,f,k}^2 &= \lambda_3 (z_k - z_{k-1})^2 + (1 - \lambda_3) \delta_{2,f,k-1}^2 \\
 R &= \frac{(2 - \lambda_1) \delta_{1,f,k}^2}{\delta_{2,f,k}^2}
 \end{aligned} \tag{3.2}$$

No qual  $z_k$  é a variável medida no tempo  $t_k$ ,  $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$  são pesos ( $0 < \lambda_i < 1$ ),  $z_{f,k}$  é a variável medida filtrada.  $\delta_{1,f}^2$  e  $\delta_{2,f}^2$  são aproximações da variância das medidas e  $R$  a razão dessas aproximações.

A primeira aproximação ( $\delta_{1,f}^2$ ) vem da variância na forma tradicional calculada através de um filtro de primeira ordem e modificada de forma a obter uma variância computacionalmente eficiente e a outra ( $\delta_{2,f}^2$ ) vem da estimativa da variância considerando o erro quadrático médio de dados sucessivos também filtrada e modificada para ser mais eficiente.

Com a razão dessas aproximações ( $R$ ) é possível determinar se o sistema está em estado estacionário. Quando o processo está em estado estacionário ambas variâncias são iguais e o valor de  $R$  é igual a 1. Raramente o valor de  $R$  atinge esse valor, então é definido pelo operador um valor crítico ( $R_{crit}$ ) que indica até que valor de  $R$  o sistema ainda pode ser considerado estacionário. Caso  $R > R_{crit}$  significa que o sistema não está mais em estado estacionário. A Equação 3.3 mostra o termo  $R$ , no numerador tem-se a aproximação da variância tradicional e no denominador a aproximação da estimativa da variância pelo erro quadrático médio.

$$R = \frac{E((z_k - z_{f,k-1})^2)}{E((z_k - z_{k-1})^2)} = \frac{\frac{(2-\lambda_1)}{2} \delta_{1,f,k}^2}{\frac{1}{2} \delta_{2,f,k}^2} \tag{3.3}$$

O  $R_{crit}$  é definido de acordo com o processo a ser realizado e tem por finalidade definir a sensibilidade do seu processo em relação à razão das variâncias, em que um valor baixo desse parâmetro indica que o estado transiente ocorrerá com pequenas variações entre as variâncias. Não há uma técnica específica para determinar o  $R_{crit}$ .

### 3.1.3 Estimação de parâmetros do modelo

Após atingir o estado estacionário, a estimação de um ou mais parâmetros é realizada para ajustar o modelo matemático ao processo físico que o representa. Para isso é utilizada a minimização dos erros quadráticos entre as variáveis medidas e as previstas



pelo modelo.

$$\begin{aligned}
\hat{p}^{est} &= \arg \min_{p^{est}} \|y - y_p\|_{R_p}^2 \\
&\text{s.t.} \\
&f(x, u, p^{est}) = 0, \\
&h(x, u, p^{est}) = y, \\
&x_{li} \leq x \leq x_{ls}, \\
&p_{li}^{est} \leq p^{est} \leq p_{ls}^{est}
\end{aligned} \tag{3.4}$$

No qual,  $p^{est}$  é o vetor de parâmetros a serem estimados,  $\hat{p}^{est}$  é o valor ótimo dos parâmetros a serem estimados.  $R_p$  é a matriz de pesos, esta matriz pode ser escolhida como o inverso da matriz de covariância do ruído.  $p_{ls}^{est}$  e  $p_{li}^{est}$  são os limites superior e inferior, respectivamente, dos parâmetros a serem estimados e  $x_{ls}$  e  $x_{li}$  são as restrições dos estados.

### 3.1.4 Otimização Econômica

Estimados os parâmetros é realizada a otimização do problema.

$$\begin{aligned}
u^* &= \arg \min_u \phi_{eco}(u, y) \\
&\text{s.t.} \\
&f(x, u, \hat{p}^{est}) = 0, \\
&h(x, u, \hat{p}^{est}) = y, \\
&x_{li} \leq x \leq x_{ls}, \\
&u_{li} \leq u \leq u_{ls}
\end{aligned} \tag{3.5}$$

No qual,  $\phi_{eco}$  é a função objetivo econômica relacionada ao problema e  $u^*$  é o valor ótimo.  $u_{ls}$  e  $u_{li}$  são as restrições relativas as condições operacionais da planta compostas respectivamente pelos limites superior e inferior associados a variável  $u$ .

Após a obtenção do ótimo  $u^*$ , o valor de  $y^*$  pode ser facilmente calculado. Em seguida  $u^*$  e  $y^*$  são enviados em forma de *setpoints* aos controladores que implementam as decisões ótimas. Assim que o processo atingir novamente o estado estacionário, a RTO atuará de novamente.

## 3.2 Otimização em tempo real com adaptação persistente de parâmetros (ROPA)

A ROPA se assemelha muito à MPA sendo realizado em dois passos: estimação de parâmetros e otimização de função econômica. Porém a estimação é realizada pelo uso de estimadores *online* sobre dados transientes em um modelo dinâmico, enquanto a otimização é feita da mesma maneira da MPA, ou seja, utilizando um modelo estacionário.

Essa combinação traz a grande vantagem da ROPA não necessitar que o sistema esteja em estado estacionário para a realização da estimação, devido ao uso dos estimadores *online* em medidas transientes. Isso permite que:

- Os parâmetros sejam estimados a qualquer momento, pois como utiliza estimação com dados transientes não há a necessidade de esperar que o sistema atinja um estado estacionário, que pode ser muito difícil de identificar ou até de acontecer em alguns sistemas.
- Não haja defasagem intrínseca entre a dinâmica do processo e a estimação do parâmetro pela RTO, devido a detecção do estado estacionário. A [Figura 3](#) é uma figura ilustrativa que representa a defasagem pela espera do estado estacionário. A linha vermelha representa o valor ótimo real de uma função objetivo genérica em um processo e a linha azul o valor ótimo obtido pela otimização em tempo real. O tempo de espera é o tempo que demora para a MPA atuar novamente após uma mudança de estado. Nota-se que o sistema muda apenas quando o estado estacionário é detectado.

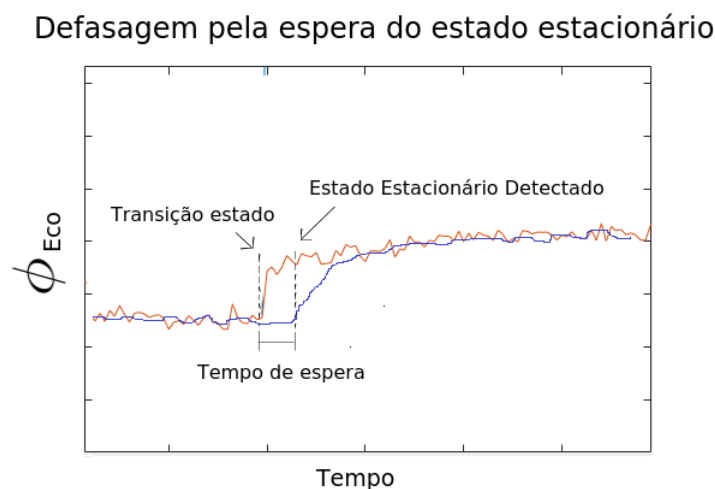


Figura 3 – Figura ilustrativa da defasagem causada pela detecção do estado estacionário.

Porém a ROPA possui suas desvantagens, uma delas é que a otimização utilizando modelos estacionários em momentos não estacionários não otimiza de fato o sistema, o resultado é sub-ótimo. Apesar disso, foi mostrado que para alguns sistemas essa aproximação tem uma performance similar à otimização rigorosa dos transientes, utilizando a DRTO. Outra desvantagem é que modelos dinâmicos não são comuns em indústrias, sendo mais utilizados modelos em estado estacionário. Apesar disso existem estudos como de Delou et al (2021) que discutem o uso de outras formas de representar sistemas dinâmicos como discutido na revisão bibliográfica.

Nas seções a seguir serão apresentadas a modelagem dinâmica e os diferentes tipos de estimadores *online* que podem ser aplicados à ROPA.

### 3.2.1 Modelo

O modelo dinâmico é representado por:

$$\begin{aligned}x_{k+1} &= F(x_k, u_k, p_k) + w_k \\ y_k &= H(x_k, u_k, p_k) + v_k\end{aligned}\tag{3.6}$$

$w_k$  e  $v_k$  são os ruídos do processo e do modelo, respectivamente, e ambos são modelados como ruídos gaussianos com média zero e covariâncias constantes  $Q \in \mathbb{R}^{nx,nx}$  e  $W \in \mathbb{R}^{ny,ny}$ , respectivamente. No caso dinâmico,  $F(x_k, u_k, p_k)$  representa a integral do modelo diferencial entre o intervalo  $[t_k, t_{k+1}]$  e o índice  $k$  representa que as variáveis estão no instante de tempo  $t_k$ . Novamente os parâmetros fixos serão ocultados.

O intervalo  $[t_k, t_{k+1}]$  de integração do modelo do modelo não deve ser confundido com o  $\Delta T^{ROPA}$  que é o intervalo de tempo entre o final de um ciclo da ROPA e o começo de outro ciclo.

### 3.2.2 Estimadores dinâmicos

Para evitar a detecção de estado estacionário, como já mencionado acima, são utilizados estimadores dinâmicos para a estimação dos parâmetros da ROPA. Diferentemente do método de estimação apresentado para a MPA, esses devem estimar os parâmetros e estados de um modelo dinâmico considerando os valores das medidas da planta. Existem diversos tipos de estimadores *online*, porém nesse trabalho serão utilizados dois deles: o filtro de Kalman estendido (EKF) e o estimador de horizonte móvel (MHE).

A comparação destes diferentes estimadores é um dos grandes diferenciais do trabalho proposto, assim uma explicação aprofundada sobre a implementação de cada um deles na ROPA será discutida.

### 3.2.2.1 Filtro de Kalman estendido

O EKF é parte da teoria de filtros bayesianos, em que a função densidade de probabilidade *a posteriori* do estado fornece uma descrição completa do estado naquele tempo (ARASARATNAM; HAYKIN, 2009). O funcionamento desses métodos está na atualização da função densidade de probabilidade *a priori* obtida em um tempo  $k$  quando houver o advento de uma nova medida de estado no tempo  $k + 1$ . Para realizar isso o método é dividido em dois passos.

O primeiro passo consiste na predição da densidade de probabilidade *a priori* para o instante  $k + 1$  considerando o instante anterior  $k$ . A Equação 3.7 descreve esse passo.

$$p(x_{k+1}|D_k) = \int_{\mathfrak{R}^{n_x}} p(x_{k+1}|x_k, u_k)p(x_k|D_k)dx_k \quad (3.7)$$

Em que  $D_k = \{u_i, y_i\}_{i=1}^k$  é o histórico de medidas e entradas do sistema até o tempo  $k$ ,  $p(x_k|D_k)$  é a função densidade de probabilidade *a posteriori* do tempo  $k$  e  $p(x_{k+1}|x_k, u_k)$  é a densidade da mudança do estado.

O segundo passo por sua vez calcula a densidade de probabilidade *a posteriori* para o instante  $k+1$ . A Equação 3.8 representa esse passo.

$$p(x_{k+1}|D_{k+1}) = \frac{p(y_{k+1}|x_{k+1}, u_{k+1})p(x_{k+1}|D_k)}{\int_{\mathfrak{R}^{n_x}} p(y_{k+1}|x_{k+1}, u_{k+1})p(x_{k+1}|D_k)dx_{k+1}} \quad (3.8)$$

Sendo  $p(y_{k+1}|x_{k+1}, u_{k+1})$  a função de máxima verossimilhança das medidas.

A junção dessas equações provê um método recursivo para aplicações de filtros não lineares. Porém na prática a resolução de integrações multidimensionais é extremamente difícil de lidar, com exceção de alguns casos específicos quando o sistema é linear e o ruído é gaussiano.

Em geral, para contornar esse problema são utilizadas aproximações, entre as quais se enquadra o EKF. O EKF utiliza um modelo dinâmico e sobre este modelo é feita uma linearização utilizando uma expansão de Taylor de primeira ordem.

$$\begin{aligned} J_{F,k} &= J_{F,k}|\hat{x}_{(k|k)} \\ J_{H,k} &= J_{H,k}|\hat{x}_{(k|k-1)} \end{aligned} \quad (3.9)$$

$$\begin{aligned} F(x_k, u_k) &\approx F(\hat{x}_{k|k}, u_k) + J_{F,k}[x_k - \hat{x}_{k|k}] \\ H(x_{k+1}) &\approx H(\hat{x}_{k+1|k}) + J_{H,k+1}[x_{k+1} - \hat{x}_{k+1|k}] \end{aligned} \quad (3.10)$$

Na Equação 3.9 o símbolo  $J$  se refere às jacobianas das funções e a notação  $|\hat{x}_{(k|k)}$  onde estão sendo avaliadas. E a Equação 3.10 apresenta a expansão de Taylor de primeira ordem.

Após a linearização do sistema são aplicadas as etapas presentes na teoria dos filtros bayesianos, sendo a primeira a predição da densidade de probabilidade *a priori* considerando o instante  $k$ :

$$x_{k+1|k} = F(\hat{x}_{k|k}, u_k) \quad (3.11)$$

$$P_{k+1|k} = J_{F,k} P_{k|k} J_{F,k}^T + Q \quad (3.12)$$

Em que  $P$  é a covariância predita. A [Equação 3.11](#) pode ser associada à [Equação 3.7](#), em que a integração do estado representa a densidade de probabilidade da mudança do estado. Já a [Equação 3.12](#) representa a incerteza da predição, sendo que a covariância  $P_{k|k}$  é a incerteza da predição passada e a covariância  $Q$  é a incerteza associada aos estados.

Em seguida o ganho de Kalman é calculado:

$$K_{k+1} = P_{k+1|k} J_{H,k+1} [J_{H,k+1} P_{k+1|k} J_{H,k+1}^T + R]^{-1} \quad (3.13)$$

$K$  é o ganho de Kalman. Esse termo relaciona a incerteza da predição em relação à incerteza do sistema, a incerteza da predição e a incerteza das medidas.

Em seguida as equações da etapa de cálculo da densidade de probabilidade no instante  $k+1$  são apresentadas:

$$P_{k+1|k+1} = P_{k+1|k} - K_{k+1} J_{H,k+1} P_{k+1|k} \quad (3.14)$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1|k} + K_{k+1} [y_{k+1} - H(\hat{x}_{k+1|k})] \quad (3.15)$$

A [Equação 3.14](#) atualiza a incerteza fazendo uma ponderação entre a incerteza da predição e a incerteza das medidas .

A [Equação 3.15](#) também é uma ponderação só que entre a predição e a estimativa das medidas, sendo o ganho de Kalman o ponderador. Isso condiz com a [Equação 3.8](#) em que a densidade de probabilidade *a posteriori* também é uma ponderação entre a predição,  $p(x_{k+1}|D_k)$ , e as medidas, função de máxima verossimilhança.

O EKF apresentado considera apenas os estados do sistema em sua formulação. Um estado aumentado é considerado para estimar os parâmetros no EKF utilizado nesta dissertação, [Equação 3.16](#). A [Equação 3.17](#) representa o modelo dinâmico utilizando o estado aumentado.

$$x^{aug} = [x, p^{est}] \quad (3.16)$$

$$\begin{aligned}
x_{k+1}^{aug} &= \begin{bmatrix} F(x_k, u_k, p_k^{est}) \\ p_k^{est} \end{bmatrix} + \begin{bmatrix} w_k \\ w_k^{p^{est}} \end{bmatrix} = F^{aug}(x^{aug}, u_k) + w_k^{aug} \\
y_k &= H(x_k^{aug}, u_k) + v_k
\end{aligned} \tag{3.17}$$

$x^{aug}$  e  $w^{aug}$  são os estados e ruídos aumentados e  $p^{est}$  os parâmetros a serem estimados. O ruído  $w$  é modelado como um ruído gaussiano com média zero e covariância constante  $Q^{p^{est}} \in \mathbb{R}^{n_x, n_x}$ . Além disso, um modelo dinâmico chamado de Passeio Aleatório (*Random Walk*), descrito por  $w_k^{p^{est}}$ , foi adicionado aos parâmetros a serem estimados para que eles possam evoluir com o tempo.

Todas as equações posteriores ao modelo dinâmico são idênticas ao do EKF já apresentado, porém no lugar de  $x$  utiliza-se a notação  $x^{aug}$ . Além disso as jacobianas podem ser representadas pelas Equações 3.18 e 3.19 e a covariância pela Equação 3.20.

$$J_{F,k} = \begin{bmatrix} \frac{dF(x_k, u_k, p_k^{est})}{dx_k} & \frac{dF(x_k, u_k, p_k^{est})}{dp_k^{est}} \\ \frac{dp_k^{est}}{dx_k} & \frac{dp_k^{est}}{dp_k^{est}} \end{bmatrix} = \begin{bmatrix} \frac{dF(x_k, u_k, p_k^{est})}{dx_k} & \frac{dF(x_k, u_k, p_k^{est})}{dp_k^{est}} \\ 0 & I_p \end{bmatrix} \tag{3.18}$$

$$J_{H,k} = \begin{bmatrix} \frac{dH(x_k, u_k, p_k^{est})}{dx_k} & \frac{dH(x_k, u_k, p_k^{est})}{dp_k^{est}} \end{bmatrix} \tag{3.19}$$

$$Q^{aug} = \begin{bmatrix} Q & 0 \\ 0 & Q^{p^{est}} \end{bmatrix} \tag{3.20}$$

### 3.2.2.2 Estimador de horizonte móvel

Como mencionado, o MHE é um estimador *online* baseado na otimização de um horizonte de medidas. Esse horizonte é separado em duas partes: um horizonte recente, que contém uma janela de medidas da qual serão estimados os estados do sistema, e outro horizonte passado, que é aproximado por um valor denominado de custo de chegada (*arrival cost*) que representa as informações do passado antes do começo da janela. Com as medidas da janela e o custo de chegada uma otimização é resolvida para obter a estimação dos estados que melhor representa o horizonte de medidas. Quando uma nova medida é coletada, há a inclusão desta medida na janela e exclusão da medida mais antiga, assim mantendo o tamanho da janela fixo mas se movendo ao longo do tempo.

A Figura 4 ilustra a ideia da divisão e estimação por janelas no estimador de horizonte móvel. O horizonte móvel é representado por 2 janelas. A cor vermelha representa a janela do instante anterior e a cor preta a janela do instante atual. O índice  $k$  é o último

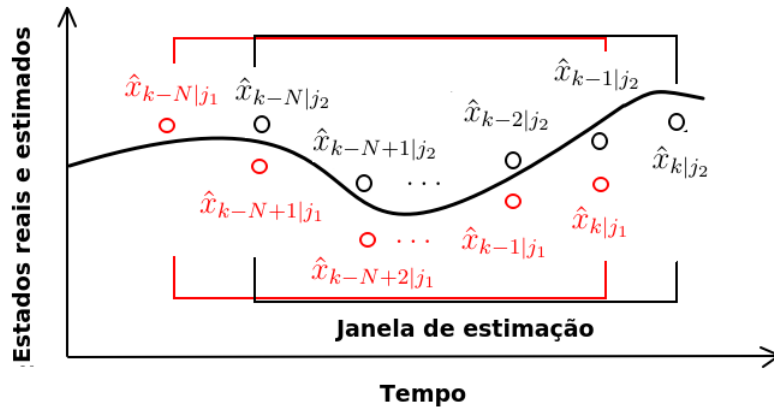


Figura 4 – Ilustração da estimação por horizonte móvel mostrando a representação de 2 janelas. (Adaptado de Hashemian e Armaou 2015).

ponto da janela e  $N$  o tamanho da janela. O custo de chegada não é apresentado na imagem.

A equação do MHE é dada por:

$$\underset{x,p}{\operatorname{argmin}} \Gamma_{k-N} + \sum_{i=k-N}^k \|y_i - h(x_i, u_i, p_i^{est})\|_{W^{-1}}^2 + \sum_{i=k-N}^{k-1} \|x_{i+1} - f(x_i, u_i, p_i^{est})\|_{Q^{-1}}^2 = \{ \hat{x}_{k-N|j}, \hat{x}_{k-N+1|j}, \dots, \hat{x}_{k|j}, \hat{p}^{est} \} \quad (3.21)$$

Em que  $\hat{x}$  e  $\hat{p}^{est}$  são os estados e parâmetros estimados respectivamente.  $N$  é o tamanho da janela,  $k$  é o último instante de tempo dentro de uma janela e  $j$  é o índice da janela a ser analisada.  $W$  e  $Q$  são as matrizes de covariância dos ruídos das medidas e dos ruídos de processo respectivamente.

$\Gamma_{k-N}$  é o custo de chegada relacionado à incerteza da informação *a priori* no começo do horizonte da janela, sendo essa informação baseada em medidas passadas. Uma aproximação dessa informação é realizada segundo duas hipóteses, a de que não é necessário a informação completa das medidas passadas, alguns poucos parâmetros conseguem representar o comportamento das medidas, e que a evolução da informação das medidas consiga ser aproximada por previsões utilizando os parâmetros que as representam (UNGARALA, 2009).

Assumindo que no começo do horizonte as variáveis são gaussianas, o custo de

chegada pode ser representado pela [Equação 3.22](#)

$$\Gamma_{k-N} = \left\| \begin{array}{c} x_{k-N} - \tilde{x}_{k-N} \\ p^{est} - \tilde{p}_{k-N}^{est} \end{array} \right\|_{P_{k-N}^{-1}}^2 \quad (3.22)$$

Em que  $P$  é a matriz de peso do custo de chegada,  $\tilde{x}_{k-N}$  e  $\tilde{p}_{k-N}^{est}$  são as estimativas considerando o horizonte inteiro de informações até o tempo  $k-N$ .

Para calcular essa aproximação do custo de chegada será utilizado o EKF. Utilizando a abordagem apresentada na seção sobre EKF, será obtido o valor de  $\tilde{x}_{k-N}$ ,  $\tilde{p}_{k-N}^{est}$  e  $P_{k-N}^{-1}$  a partir dos valores de  $x_{k-N-1}$ ,  $p_{k-N-1}^{est}$  e  $P_{k-N-1}$ . O custo de chegada é recalculado sempre que a janela se move. Na primeira janela do MHE esse ponto no tempo  $k-N-1$  pode não ser conhecido, sendo utilizado uma estimativa inicial  $x_0^{aug} = [x_0, p_0^{est}]$ , e nas janelas seguintes é possível utilizar o valor de  $x_{k-N}$  da janela anterior como estimativa de  $x_{k-N-1}$ .

Ungarala (2009) apresenta uma interpretação probabilística para o MHE. Utilizando a regra de Bayes, a função de densidade de probabilidade conjunta condicional dentro de um horizonte de medidas pode ser escrita como uma equação de proporcionalidade da forma:

$$p(X_m|Y_m) \propto p(Y_m|X_m)p(X_m|Y_{1:k-m}) \quad (3.23)$$

Em que  $p(X_m|Y_{1:k-m}) = p(x_{k-m+1}, x_{k-m+2}, \dots, x_k|y_1, y_2, \dots, y_{k-m})$  é a função de densidade de probabilidade conjunta *a priori* dos estados condicionada pelas medidas anteriores ao horizonte de medida e  $p(Y_m|X_m) = p(y_{k-m+1}, y_{k-m+2}, \dots, y_k|x_{k-m+1}, x_{k-m+2}, \dots, x_k)$  é a função de verossimilhança conjunta.

Assumindo  $X_m$  como uma cadeia de markov de ordem 1, a função de densidade de probabilidade conjunta condicional fica:

$$p(X_m|Y_m) = c_1 \left( \prod_{i=k-m+1}^k p(y_i|x_i) \right) \left( \prod_{i=k-m+1}^{k-1} p(x_{i+1}|x_i) \right) p(x_{k-m+1}|Y_{1:k-m}) \quad (3.24)$$

Em que  $c_1$  é uma constante e  $p(y_i|x_i)$  a função de verossimilhança em cada medida do horizonte. A função de densidade de probabilidade conjunta *a priori* é dividida em duas partes,  $p(x_{i+1}|x_i)$  descreve a transição de estado utilizando o estado no instante anterior como condição para o estado no instante posterior e  $p(x_{k-m+1}|Y_{1:k-m})$  é a função *a priori* do estado no começo do horizonte, em que o primeiro estado é condicionado pelas medidas anteriores ao horizonte de medidas.

A transição de estado é definida por  $p(x_{i+1}|x_i) = p_w(x_{k+1} - f(x_k))$  e é considerada uma distribuição  $\mathcal{N}(0, Q)$ , e a função de verossimilhança é definida por  $p(y_i|x_i) = p_v(y_k -$



$h(x_k)$ ), sendo considerada uma distribuição  $\mathcal{N}(0, R)$ . Assim a função conjunta de densidade de probabilidade fica:

$$p(X_m|Y_m) = c_2 \left( \prod_{i=k-m+1}^k e^{-\frac{1}{2} \|y_i - h(x_i)\|_{R^{-1}}^2} \right) \left( \prod_{i=k-m+1}^{k-1} e^{-\frac{1}{2} \|x_{i+1} - f(x_i)\|_{Q^{-1}}^2} \right) p(x_{k-m+1}|Y_{1:k-m}) \quad (3.25)$$

Em que  $c_2$  é uma constante e os termos exponenciais são as funções densidade de probabilidade da transição de estados e da função de verossimilhança para uma distribuição normal, sendo o termo  $\|\alpha\|_A^2$  a forma quadrática de  $\alpha^T A \alpha$ . Utilizando o negativo do logaritmo função de densidade conjunta e minimizando a função em relação aos estados, chega-se à equação do estimador de horizonte móvel.

$$\min_{X_m} \sum_{i=k-m+1}^k \|y_i - h(x_i)\|_{R^{-1}}^2 + \sum_{i=k-m+1}^{k-1} \|x_{i+1} - f(x_i)\|_{Q^{-1}}^2 + \Gamma(x_{k-m+1}) \quad (3.26)$$

Em que  $\Gamma(x_{k-m+1}) = -\ln p(x_{k-m+1}|Y_{1:k-m})$  é o custo de chegada que considera as informações *a priori*. Assumindo que  $p(x_{k-m+1}|Y_{1:k-m})$  é uma gaussiana multivariável de  $\mathcal{N}(\tilde{x}_{k-m+1}, \tilde{P}_{k-m})$ , a variável  $\Gamma$  pode ser descrita por:

$$\Gamma(x_{k-m+1}) = \|x_{k-m+1} - \tilde{x}_{k-m+1}\|_{\tilde{P}_{k-m}^{-1}}^2 \quad (3.27)$$

Comparando a [Equação 3.21](#) e [Equação 3.26](#), tem-se praticamente a mesma equação porém sem considerar a estimação dos parâmetros.

Diferentes esquemas de obtenção da variável custo de chegada podem ser considerados como descrito em ([ELSHEIKH et al., 2021](#)), porém para esta dissertação será utilizado o custo de chegada calculado pelo EKF.



## 4 Estudo de Caso

Este capítulo apresenta a aplicação da MPA e da ROPA em um sistema experimental que simula a operação de *Gas Lift* com o objetivo de validar as metodologias e permitir quantificar uma comparação no uso da ROPA em relação à MPA, além de comparar a diferença entre o uso de diferentes estimadores *online* na ROPA e analisar o comportamento da ROPA em um experimento piloto.

### 4.1 Descrição do processo

Nesta seção será apresentada uma breve introdução sobre a extração de petróleo por *Gas Lift*, a descrição do sistema real que realiza esta operação e a descrição do equipamento experimental projetado para simular o sistema real.

A extração de petróleo no mar, também conhecida como *offshore*, teve seu início entre os anos de 1930 e 1950 na Venezuela e no Golfo do México. A primeira descoberta de jazida de petróleo *offshore* no Brasil ocorreu em 1968, mas a atividade só expandiu nos meados dos anos de 1980 (NETO; COSTA, 2006).

Na maioria dos casos o petróleo no fundo do mar não tem pressão suficiente para chegar a superfície, sendo necessários métodos artificiais de extração. O *Gas Lift* é uma das técnicas utilizadas para permitir esta extração.

O *Gas Lift* é fundamentado nos princípios de escoamento em que adiciona-se gás de modo a facilitar o escoamento do fluido que queremos extrair. A adição de gás no petróleo faz com que a densidade da mistura seja menor que a densidade do petróleo. A redução da densidade reduz a pressão hidrostática do sistema, e isso gera um aumento na vazão do fluido. Entretanto, utilizar muito gás pode aumentar perda de carga e reduzir a vazão, existindo um ponto ótimo de gás a ser injetado. A [Figura 5](#) representa o efeito da injeção de gás.

Devido ao alto custo associado à extração, a busca pelo ponto ótimo de operação é fundamental para a maximização do lucro. Além disso, devido às mudanças constantes que podem ocorrer durante a extração, é vantajoso o uso de métodos de otimização em tempo real para que a todo instante a produção seja máxima.

A [Figura 6](#) é uma representação simplificada dos principais componentes da operação. A extração é composta de duas tubulações principais:

- Poço: A tubulação que liga o riser ao reservatório do fluido a ser extraído, representado pela nuvem cinza. O poço é composto de duas partes, uma interna que esta conectada

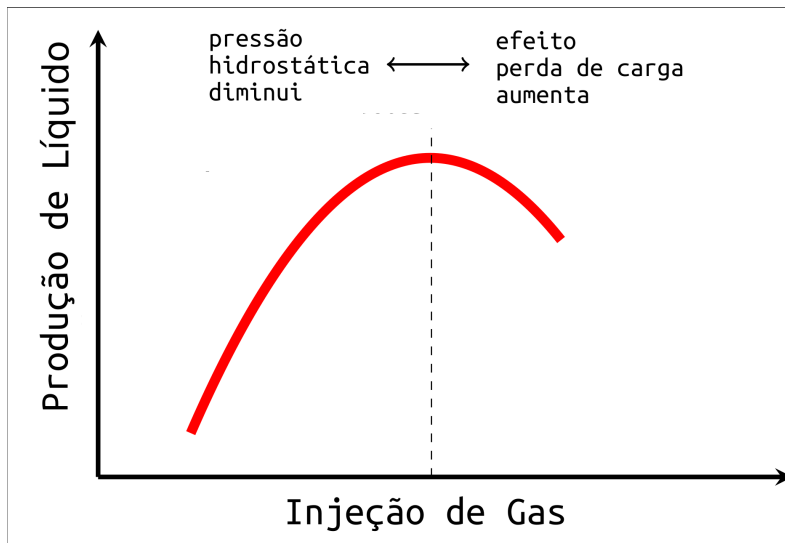


Figura 5 – Representação do efeito da injeção de gás sobre a produção de líquido.

ao reservatório e responsável pelo transporte do fluido, e outra externa, denominada de espaço anular em que é adicionado o gás que será utilizado para facilitar a extração.

- Riser: A tubulação que liga o poço à plataforma de produção e é responsável pelo transporte do fluido que é extraído do poço para as diferentes plataformas que irão processá-lo.

A plataforma é responsável pela operação de separação e distribuição dos diferentes compostos extraídos do poço.




Figura 6 – Representação de *Gas Lift* em poço de extração offshore.

Para representar essa operação, um equipamento experimental foi projetado na Universidade Norueguesa de Ciência e Tecnologia (NTNU), na Noruega. Neste equipamento foi implementada a camada de RTO para o estudo presente nesta dissertação.

A Figura 7 apresenta o esquema do equipamento. Comparando com a operação de extração em plataformas, o tanque de água seria o reservatório de petróleo. A bomba e as válvulas de controle representam a dinâmica do poço de petróleo. As tubulações horizontais, linhas horizontais após as válvulas do reservatório na Figura 7, tem 2 cm de diâmetro, 3 m de comprimento e representam os poços. As tubulações verticais, com 2 cm de diâmetro, 3,5 m de comprimento, representam os risers. Por último, as válvulas de injeção de ar simulam a injeção de gás no espaço anular do poço.

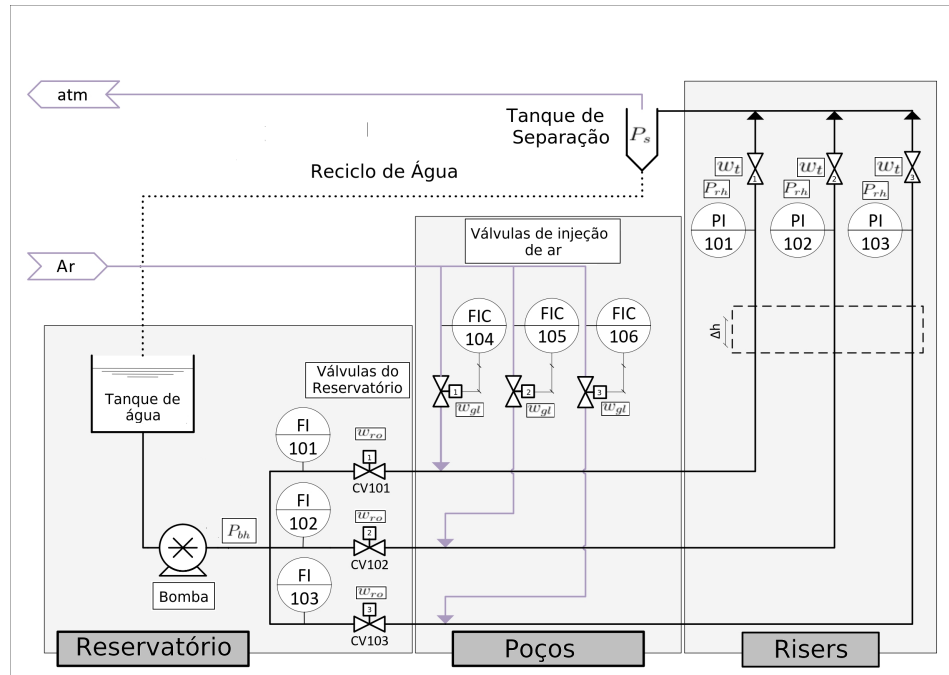


Figura 7 – Esquema do experimento que simula a operação de *Gas Lift*.

O experimento opera com vazões de água de até 8 kg/min e pressões menores que 1,025 bar. Cada tubulação está associada a um poço diferente, ou seja, três processos em paralelo de extração e isso torna a otimização mais interessante, pois a injeção de gás pode ser otimizada considerando diferentes condições de operação para cada poço, sendo essas condições conectadas por restrições que afetam todo o sistema, como uma quantidade máxima de ar disponível para os três poços.

O equipamento completo é composto por uma bomba, três tubulações, um tanque de água, um separador, medidores de vazão e pressão e três válvulas de injeção de ar que contêm controladores ( $FIC104, FIC105, FIC106$ ) que controlam a vazão da injeção de ar no sistema. Adicionalmente, três válvulas com controladores estão localizadas à jusante da bomba ( $CV101, CV102, CV103$ ) e seus controladores são utilizados para simular distúrbios na vazão de cada poço durante os experimentos, essas válvulas também possuem sensores ( $FI101, FI102, FI103$ ) que medem a vazão. Outras três válvulas manuais, localizadas no topo antes do separador, estão sempre totalmente abertas e possuem sensores para medir a pressão no topo. As medidas utilizadas na etapa de detecção em estado estacionário

serão as medidas de vazão dos sensores  $FI101, FI102, FI103$ .

Por fim, a injeção de gás realizada sobre o sistema é de fundamental importância para a eficiência da extração. Sendo que pouco gás resultará numa extração sub-ótima, mais gás produziria mais produto, e muito gás dificultaria o escoamento do fluido e por conseguinte resultaria também em uma extração sub-ótima. Assim o objetivo da RTO aplicada a essa estrutura seria de obter a quantidade ideal de gás a ser adicionada de modo a maximizar a obtenção do produto do reservatório, considerando que o sistema possui uma quantidade máxima de ar que pode ser injetada em cada poço e outra para o sistema como um todo.

## 4.2 Modelo do equipamento experimental

A seguir é apresentado o modelo de estado estacionário e de estado transiente para o equipamento.

Associando as variáveis descritas na fundamentação teórica com o experimento temos que as medidas ( $y$ ), as variáveis manipuladas ( $u$ ) e os parâmetros a serem estimados ( $p^{est}$ ) são representados pelas variáveis de processo na lista abaixo.

- $y = [w_{ro,1,2,3}, P_{rh,1,2,3}]$
- $u = w_{gl,1,2,3}$
- $p^{est} = [C_{pr,1,2,3}, \theta_{1,2,3}]$

Sendo  $w_{ro}$  e  $P_{rh}$ , respectivamente, a vazão do reservatório ( $kg/min$ ) e a pressão no topo do riser ( $bar$ ),  $w_{gl}$  a vazão de injeção de ar ( $sL/min$ ),  $C_{pr}$  é a característica geométrica da válvula do topo. A unidade da injeção de ar está em litros na condição padrão de temperatura e pressão (*standard litre - sL*).  $\theta$  é um parâmetro empírico que representa a dinâmica da vazão do reservatório, ele é apresentado na seção 4.3. Os índices 1, 2, 3 indicam os poços a serem analisados, esses termos serão omitidos na descrição da modelagem, pois os três poços são igualmente modelados.

Outra questão é que apesar da modelagem da vazão levar em consideração o valor de  $w_{gl}$ , como será apresentado posteriormente, ele é na verdade implementado como *setpoint* dos controladores  $FIC104, FIC105, FIC106$ .

### 4.2.1 Modelo em estado estacionário

O modelo foi baseado no trabalho de Krishnamoorthy (2016) que modela o processo de *Gas Lift* em operações subaquáticas de extração de petróleo. Algumas hipóteses foram consideradas para a modelagem:

- Reservatório contém somente líquido. Isso decorre do fato do ar ser totalmente separado da água nos tanques.
- A massa do sistema, composto pela soma das massas de líquido e gás presentes no poço e no riser, é proporcional à vazão mássica (Equação 4.5).
- Temperatura constante durante a realização experimental.
- Perda de carga em fluxo laminar
- A densidade de líquido é constante
- Gás ideal

A Figura 8 apresenta um esquema simplificado do experimento indicando as variáveis utilizadas na modelagem.

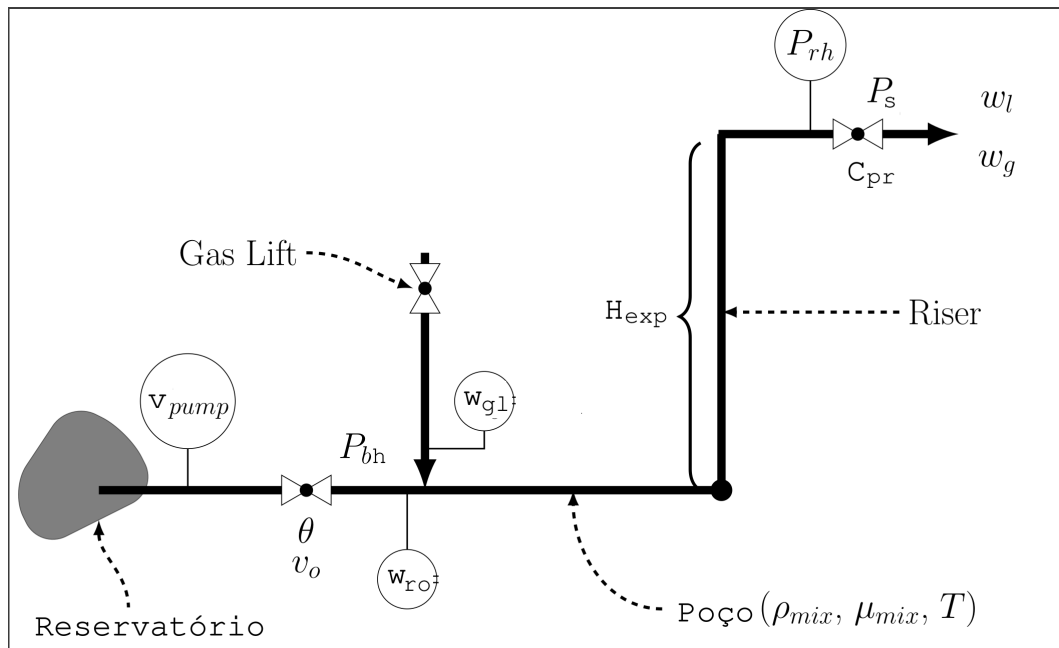


Figura 8 – Esquema simplificado do experimento indicando as variáveis utilizadas na modelagem.

O modelo em estado estacionário é apresentado a seguir. O balanço de massa é dado por:

$$w_t = w_g + w_l \quad (4.1)$$

$$w_g = w_{gl} \quad (4.2)$$

$$w_l = w_{ro} \quad (4.3)$$

$$m_t = m_g + m_l \quad (4.4)$$

$$\frac{m_g}{m_t} = \left( \frac{w_{gl}}{w_t} \right) \quad (4.5)$$

$$V_t = V_g + V_l = \frac{m_l}{\rho_l} + \frac{m_g}{\rho_g} \quad (4.6)$$

Em que  $m_t$  é a massa total do experimento,  $m_l$  a massa de líquido e  $m_g$  a massa de gás.  $w_g$ ,  $w_l$  e  $w_t$  são, respectivamente, as vazões de gás, líquido e total no topo do riser.  $V_t$  é o volume total,  $\rho_l$  e  $\rho_g$  são as densidades de líquido e gás respectivamente.

As densidades são dadas por:

$$\rho_{mix} = \frac{m_t}{V_t} = \frac{m_g + m_l}{V_t} \quad (4.7)$$

$$\rho_g = \frac{P_{rh}M_g}{RT} \quad (4.8)$$

Sendo  $M_g$  a massa molecular do gás,  $R$  a constante universal dos gases,  $\rho_{mix}$  a densidade da mistura e  $T$  a temperatura do experimento.  $P_{rh}$  é a pressão do topo.

Substituindo as equações de densidade do gás e volume na [Equação 4.7](#), obtém-se:

$$\rho_{mix} = \frac{(m_g + m_l)}{\frac{m_l}{\rho_l} + \frac{m_g}{\frac{P_{rh}M_g}{RT}}} \quad (4.9)$$

Rearranjando a [Equação 4.9](#):

$$\rho_{mix} = \frac{(m_g + m_l)P_{rh}M_g\rho_l}{m_lP_{rh}M_g + \rho_lRTm_g} \quad (4.10)$$

A pressão no início do poço é dada por:

$$P_{bh} = P_{rh} + \rho_{mix}gH_{exp} + \frac{128\mu_{mix}(L_{exp})}{\pi D_{exp}^4\rho_{mix}} \quad (4.11)$$

$P_{bh}$  é a pressão no início do poço, que é a pressão no topo do riser,  $P_{rh}$ , adicionada a pressão hidrostática e a perda de carga por atrito em tubos com fluxo laminar, equação de Darcy-Weisbach.  $\mu_{mix}$  é a viscosidade e  $H_{exp}$ ,  $L_{exp}$  e  $D_{exp}$  são, respectivamente, a altura, comprimento e diâmetro da tubulação. O comprimento do tubo engloba tanto o poço como o riser.



A pressão no topo do riser foi calculada por um rearranjo da equação de vazão de fluido da válvula do riser, [Equação 4.12](#).

$$w_t = C_{pr} \sqrt{\rho_{mix}(P_{rh} - P_s)} \quad (4.12)$$

A pressão no topo do riser é dada por:

$$P_{rh} = \frac{w_t^2}{\rho_{mix} C_{pr}^2} + P_s \quad (4.13)$$

Em que  $P_s$  é a pressão do separador, no caso do experimento é a pressão atmosférica, e  $C_{pr}$  é o coeficiente da válvula do riser.

Por último, é necessário apresentar a equação da vazão do reservatório. Inicialmente a [Equação 4.14](#) tinha sido proposta, que é uma aproximação em que a vazão do reservatório é proporcional a diferença de pressão entre a cabeça do poço e o reservatório.

$$w_{ro} = PI(P_{res} - P_{bh}) \quad (4.14)$$

$$w_{ro} = PI \left(1 - \frac{P_{bh}}{P_{res}}\right) P_{res} \quad (4.15)$$

Em que  $PI$  é o índice de produção, um parâmetro que indica o índice de produtividade em extrações por Gas Lift, e  $P_{res}$  a pressão após a bomba. A [Equação 4.15](#) é um rearranjo da equação [Equação 4.14](#).

Porém o comportamento linear da [Equação 4.14](#) não condizia com a não linearidade da vazão da bomba. Essa não linearidade pode ser notada na [Figura 9](#), esta figura foi obtida a partir de dados do experimento e mostra uma aproximação da curva do crescimento da vazão de líquido ( $w_{ro}$ ) com a injeção de ar ( $w_{gl}$ ).

Assim a [Equação 4.16](#) foi proposta.

$$w_{ro} = (vo^{0.0026} - 0.9937)(1 - 0.0050w_{gl}^2)v_{pump}^2 + 0.0485w_{gl}^2 \quad (4.16)$$

Em que  $vo$  e  $v_{pump}$  são variáveis que podemos manipular pelo experimento e serão utilizadas como distúrbios do estado da planta.  $vo$  é a abertura da válvula, de 0 (fechado) a 1 (aberto), e  $v_{pump}$  é o percentual de velocidade da bomba em relação à velocidade máxima, i.e 35% da  $v_{pump}^{max}$ .

Essa equação empírica foi baseada na [Equação 4.15](#), o primeiro termo referente à abertura da válvula,  $vo$ , representa o índice de produção  $PI$ . O segundo termo faz uma aproximação da razão das pressões utilizando a vazão de gás,  $w_{gl}$ , e aproxima a variável

**Variação da vazão de líquido em razão da injeção do ar  
( $v_o$  e  $v_{pump}$  constante)**




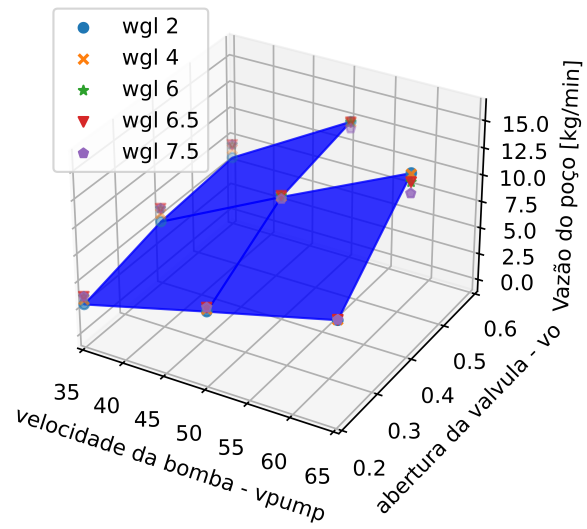
Figura 9 – Não linearidade da vazão de líquido em relação a injeção de ar.

da pressão do reservatório pela variável de velocidade da bomba,  $v_{pump}$ . O último termo foi uma adição utilizando a vazão  $w_{gl}$  que ajudou na modelagem desta variável. O formato desta equação foi obtido por tentativa e erro e escolher a forma da [Equação 4.15](#) foi apenas uma tentativa de aproximar o equacionamento da variável ao da equação proposta inicialmente.

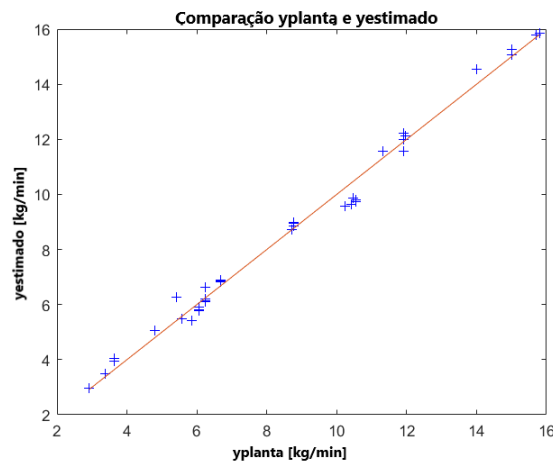
Para obter os parâmetros da [Equação 4.16](#) foram coletados dados de medidas de vazão de líquido em diferentes condições de injeção de ar, abertura de válvula e velocidade da bomba e com essas medidas uma minimização quadrática foi realizada para estimar os valores dos parâmetros da equação. Os dados utilizados nesse estudo e a comparação dos valores medidos e estimados pela minimização quadrática são apresentados na [Figura 10](#).

A [Figura 10a](#) mostra a vazão do poço,  $w_{ro}$ , em relação às três variáveis que controlam o comportamento do poço,  $v_o$ ,  $v_{pump}$  e  $w_{gl}$ , os pontos destacados são aqueles utilizados na análise e a área desenhada é para facilitar a visualização. A [Figura 10b](#) e a [Figura 10c](#) mostram a comparação e desvio, respectivamente, entre os valores estimados pela equação apresentada em relação aos valores medidos pelos sensores. Nota-se que a maioria dos desvios estão na faixa de 2-8% e não ultrapassam o valor de 20%, ou seja, a princípio a equação proposta consegue identificar adequadamente a dinâmica do experimento para os valores de  $v_o$ ,  $w_{gl}$  e  $v_{pump}$  dentro das faixas de valores apresentadas nos eixos da [Figura 10a](#).

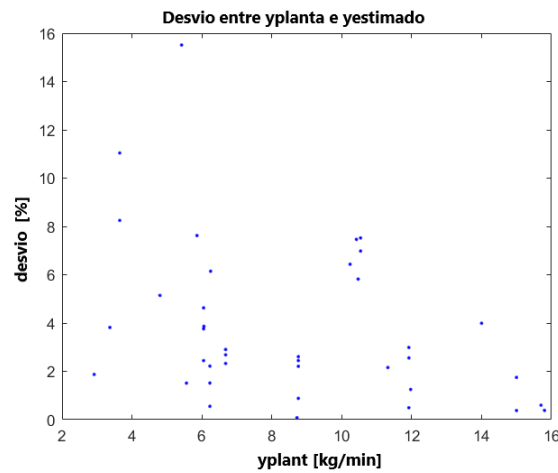
Vazão do experimento em função de  $v_o$ ,  $v_{pump}$  e  $w_{gl}$



(a) Dados para equação empírica.



(b) Comparação entre valores medidos e calculados pelo modelo.



(c) Desvio relativo em módulo entre modelo e planta.

Figura 10 – Análise dos dados da planta em relação ao modelo ajustado por minimização quadrática.

### 4.2.2 Modelo em estado transiente

O modelo em estado transiente possui as mesmas premissas do modelo de estado estacionário e seu equacionamento é similar. As equações de densidade, pressão e vazão do reservatório se mantêm e as equações do balanço de massa foram alteradas para:

$$\dot{m}_g(t) = w_{gi}(t) - w_g(t) \quad (4.17)$$

$$\dot{m}_l(t) = w_{ro}(t) - w_l(t) \quad (4.18)$$

$$xL(t) = \frac{m_l(t)}{m_l(t) + m_g(t)} \quad (4.19)$$

$$w_l(t) = xL(t)w_t(t) \quad (4.20)$$

$$V_t(t) = \frac{m_l(t)}{\rho_l} + \frac{m_g(t)}{\rho_g(t)} \quad (4.21)$$

$$w_t(t) = w_g(t) + w_l(t) \quad (4.22)$$

$w_g$  e  $w_l$  são a vazão no topo de gás e líquido, respectivamente, e  $xL$  é a fração de líquido na mistura.

## 4.3 Estimação dos parâmetros do modelo

Para a otimização em tempo real são necessários parâmetros que representem adequadamente o comportamento do sistema, para que quando esses valores sejam estimados o modelo reflita o que ocorre na planta. Assim, essa escolha é fundamental para que a RTO tenha uma otimização econômica satisfatória.

Considerando o equipamento experimental, os modelos propostos e as medidas obtidas de sensores, tem-se que a vazão do poço e a pressão no topo da coluna,  $w_{ro}$  e  $P_{rh}$ , são variáveis que afetam a dinâmica do sistema e tem influência na representação do comportamento do experimento. Desse modo os parâmetros escolhidos para a estimação serão provenientes do modelo dessas duas variáveis, modelados pela [Equação 4.13](#) e pela [Equação 4.16](#).

A [Equação 4.13](#) é composta de dois parâmetros,  $P_s$  e  $C_{pr}$ , e duas variáveis,  $w_t$  e  $\rho_{mix}$ , logo a escolha de parâmetros a serem estimados poderia ser feita sobre os dois parâmetros da equação ou sobre parâmetros relacionados ao equacionamento das duas variáveis.

Porém, considerando o sistema experimental, a pressão de separação será constante pois a separação da água e ar é feita à pressão atmosférica e  $w_t$  e  $\rho_{mix}$ , vazão de saída do sistema e densidade da mistura, já serão influenciadas pela [Equação 4.16](#). Assim,  $C_{pr}$  foi escolhido inicialmente como parâmetro de estimação da RTO para que a pressão no topo da coluna seja estimada adequadamente.

A [Equação 4.16](#), por sua vez, é uma equação empírica que não tem relação com outras partes do sistema, apenas com as variáveis  $v_o$ ,  $v_{pump}$ , que são os parâmetros fixos de caracterização do experimento, e  $w_{gl}$ , que é a variável manipulada. Logo, a escolha do parâmetro a ser estimado foi realizada considerando os valores associados a essas variáveis. Diversas possibilidades foram testadas e, por observação, a estrutura representada pela [Equação 4.23](#) foi selecionada para a estimação com o uso de um parâmetro definido como  $\theta$ .

$$w_{ro} = (v_o^{0.0026} - 0.9937)(1 - 0.0050w_{gl}^2)v_{pump}^2 + \theta w_{gl}^2 \quad (4.23)$$

Um estudo da identificabilidade dos parâmetros foi realizado, a [Figura 11](#) mostra os resultados. Nesse estudo foi estimado o valor dos parâmetros do experimento usando as medidas obtidas dos sensores para uma condição fixa de operação.

Foram realizados 100 experimentos independentes em estado estacionário para estimação dos parâmetros. Os histogramas dos parâmetros são apresentados na diagonal principal e os demais gráficos são os estudos de identificabilidade entre os parâmetros. No histograma a linha vermelha representa a média das medidas. Nos outros gráficos as médias dos valores dos parâmetros são representadas pelos pontos vermelhos e as linhas pretas correspondem a um intervalo de 95% de confiança.

Analisando a [Figura 11](#), os histogramas mostram a distribuição dos valores de  $\theta$  e  $C_{pr}$  para os três poços. O  $C_{pr}$  não exhibe grande diferença com a presença de ruídos, menor que 5%, esse comportamento condiz com o esperado, pois o coeficiente da válvula só varia se houver alteração na geometria da válvula.

Já o  $\theta$  apresenta maior diferença, porém por ser proveniente de uma equação empírica não há um comportamento esperado para tal variável e ela apenas ajusta a equação empírica de modo a atingir o valor esperado de  $w_{ro}$ .

Outra questão avaliada foi a correlação entre os parâmetros nota-se que a maioria dos gráficos são elipses na horizontal, isso mostra que os valores dos parâmetros não tem correlação entre eles, pois a alteração no valor de um parâmetro não afetará o outro parâmetro e isso era esperado pois são três poços distintos. Existem 3 exceções, elipses na diagonal, que são os valores de parâmetros de um mesmo poço que de fato estão associados. Isso demonstra a independência de um poço em relação aos demais.

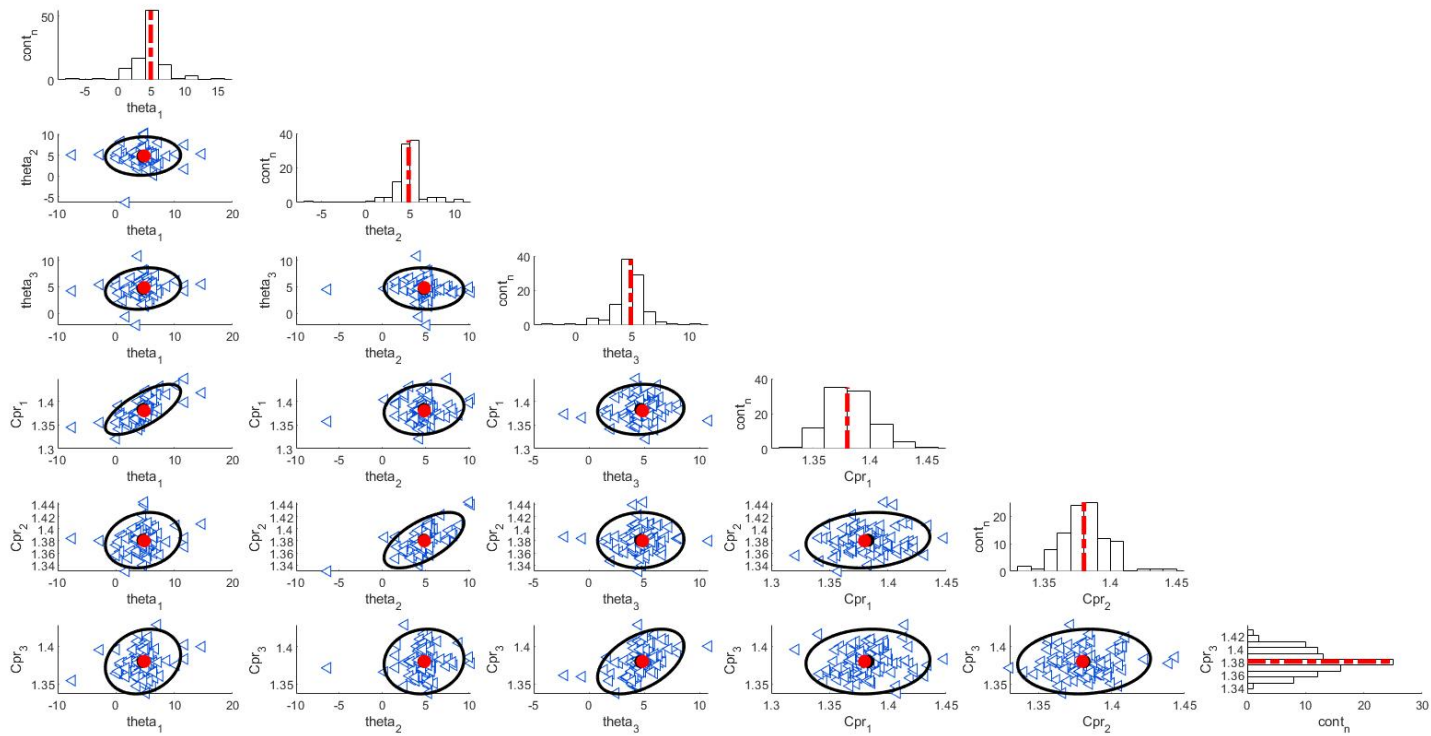


Figura 11 – Histograma e estudo de identificabilidade para 100 experimentos independentes de estimação de parâmetros.

## 4.4 Otimização

A realização da RTO depende da otimização de uma função objetivo que represente o ganho ou perda econômica do processo. Em um processo de extração essa função pode ser complexa e variar segundo as condições de preços dos produtos, porém para a análise do experimento uma representação simples será utilizada. A [Equação 4.24](#) considera que os ganhos provenientes advêm da produção de água no topo,  $w_{ro}$ , e que há custos devido a injeção de gás,  $w_{gl}$ .

$$\phi_{eco} = \alpha \sum_{i=1}^{nw} w_{ro,i} - \beta \sum_{i=1}^{nw} w_{gl,i} \quad (4.24)$$

Os parâmetros  $\alpha$  e  $\beta$  são fatores de custo associados a cada variável,  $nw$  é a quantidade de poços a serem analisados.

Esse o custo reflete o comportamento desejado para operação de gás lift, ou seja, analisará a quantidade ideal de gás para a máxima produção da planta, [Figura 5](#). Relembrando que a injeção de gás diminui a pressão hidrostática do sistema e aumenta a produção de líquido, mas utilizar muito gás aumenta o efeito da perda de carga e existe um momento em que esse efeito domina o sistema e a produção diminui.

A otimização também é sujeita as restrições presentes na [Equação 4.25](#).

$$\begin{aligned}
f(x_i, u_i, p_i) &= 0 & \forall i \in I \\
y_i - Hx_i^T &= 0 & \forall i \in I \\
\sum_{i=1}^{nw} u_i &\leq u_{MAX}^{TOTAL} & \forall i \in I \\
x_i^{li} &\leq x_i & \forall i \in I \\
u_i^{li} &\leq u_i \leq u_i^{ls} & \forall i \in I
\end{aligned} \tag{4.25}$$

Em que os sobrescritos  $ls$  e  $li$  representam os limites superior e inferior das variáveis,  $u_{MAX}^{TOTAL}$  é um valor máximo de injeção de gás no sistema e  $I = \{1, 2, 3\}$  é o conjunto dos poços.  $H$  é uma matriz de 0 e 1, em que o valor 1 está posicionado nas variáveis que são medidas experimentalmente. As variáveis  $x_i$ ,  $y_i$ ,  $u_i$ ,  $p_i$  são apresentadas na [Equação 4.26](#).

$$\begin{aligned}
x_i &= [w_{t,i}, P_{bh,i}, \rho_{mix,i}, \rho_{g,i}, m_{g,i}, m_{l,i}, w_{ro,i}, P_{rh,i}] \\
u_i &= w_{gl,i} \\
p_i &= [C_{pr,i}, \theta_i] \\
y_i &= Hx_i = [w_{ro,i}, P_{rh,i}]
\end{aligned} \tag{4.26}$$

## 4.5 Resultados

### 4.5.1 Validação do modelo

Para validar o modelo, diversas condições de operação foram definidas e foram comparados os valores entre as medidas do modelo e dos sensores. Nessa análise foram variados os valores de  $w_{gl}$ ,  $v_{pump}$  e  $vo$  e foram fixados os parâmetros de estimação  $C_{pr}$  e  $\theta$ . Estes parâmetros aproximam o comportamento do modelo proposto ao comportamento do experimento, então mantê-los constantes permite avaliar a predição do modelo considerando apenas as variáveis que podem ser alteradas pelo equipamento experimental ( $w_{gl}$ ,  $v_{pump}$  e  $vo$ ), ou seja, sem influência da estimação dos parâmetros  $C_{pr}$  e  $\theta$ . A comparação detalhada está demonstrada no Apêndice A. A [Figura 12](#) é uma das situações estudadas.

As linhas vermelhas representam as medidas calculadas pelo modelo, enquanto as linhas amarelas são as médias das medidas obtidas pelos sensores. Nota-se que há um proximidade muito grande nos valores de  $w_{ro}$ , mesma ordem de grandeza e diferença de 10% ou menos entre a maioria das condições. Por sua vez, os valores de  $P_{rh}$  estão na mesma ordem de grandeza porém o modelo não prediz de maneira tão precisa como a medida anterior. Apesar dessas diferenças entre valores, esse modelo foi considerado satisfatório para utilização no equipamento experimental já que o modelo nominal indica

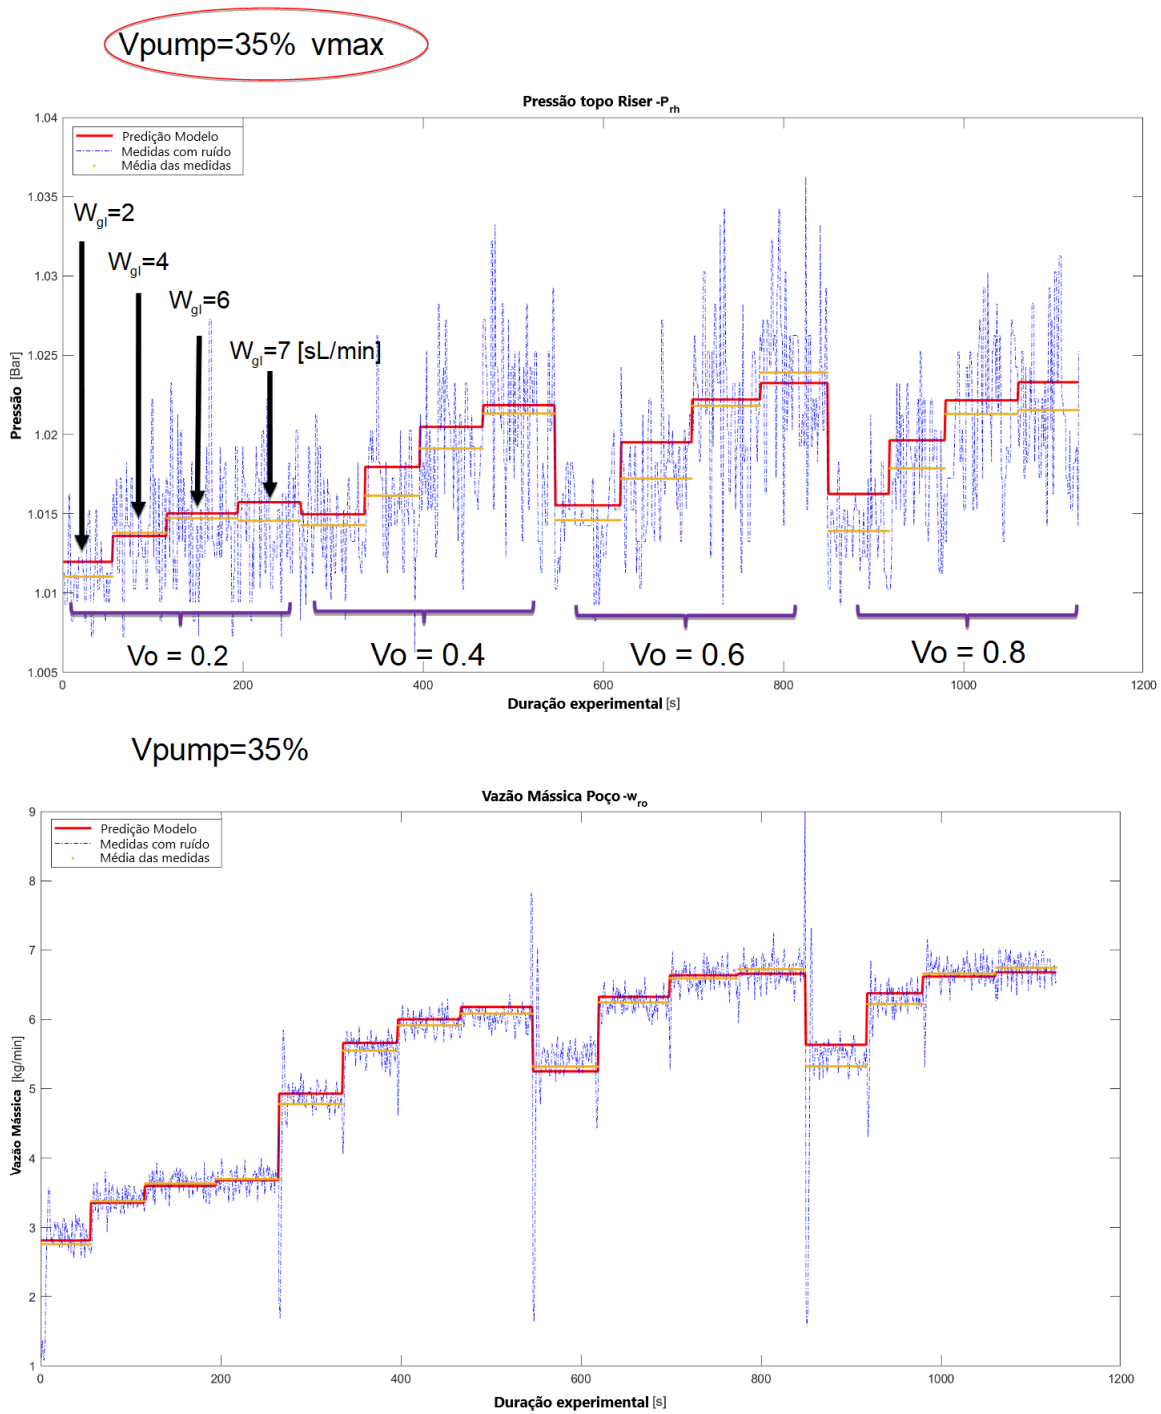


Figura 12 – Validação do modelo de estado estacionário.

uma comparação sem a adaptação dos estados, ou seja, os valores estão próximos mesmo com os parâmetros a serem estimados tendo sido fixados e na etapa de estimação de parâmetros essas medidas serão refinadas.



### 4.5.2 Análise RTO MPA

Antes da implementação do método ROPA e da comparação entre as diferentes otimizações, foi realizado um teste para verificar se a implementação da MPA conseguiria calcular o ponto de operação ótimo da planta. Para isso, três cenários com funções objetivo diferentes foram avaliados:

1. Os três poços estão nas mesmas condições de operação e todos os poços têm o mesmo fator de custo em  $\$/l$ .

$$\phi_{eco} = 10 \sum_{i=1}^3 w_{ro,i} - 0.5 \sum_{i=1}^3 w_{gl,i} [\$/medida] \quad (4.27)$$

2. Os três poços estão nas mesmas condições de operação, mas há uma leve diferença entre o fator de custo.

$$\phi_{eco} = 10 \sum_{i=1}^3 w_{ro,i} - 0.5w_{gl,1} - 1.0w_{gl,2} - 1.5w_{gl,3} \quad (4.28)$$

3. Os três poços estão nas mesmas condições de operação, mas há uma grande diferença entre o fator de custo.


$$\phi_{eco} = 10 \sum_{i=1}^3 w_{ro,i} - 0.5w_{gl,1} - 2.0w_{gl,2} - 4.0w_{gl,3} \quad (4.29)$$

A análise foi realizada mantendo as mesmas condições durante todo o período, em que a abertura de válvula ( $vo$ ) e a velocidade da bomba ( $v_{pump}$ ) para os três poços foram de 0.4, 40% de abertura da válvula, e 40% velocidade máxima da bomba respectivamente. Além disso estavam sujeitos as mesmas restrições, [Equação 4.30](#).

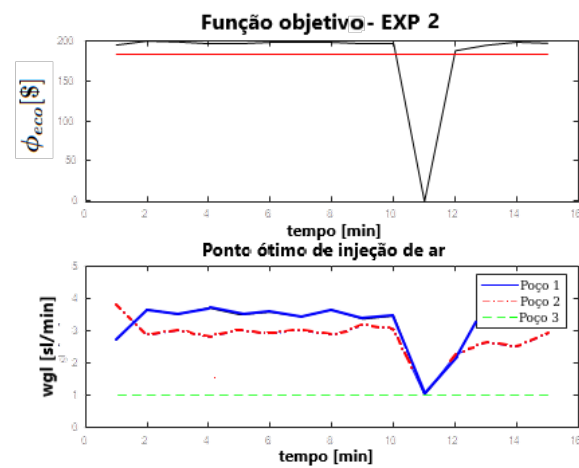
$$\begin{aligned} f(x_i, u_i, p_i) &= 0 & \forall i \in I \\ \sum_{i=1}^3 u_i &\leq 7.5 \quad [sL/min] & \forall i \in I \\ 0 &\leq x_i & \forall i \in I \\ 0 &\leq y_i & \forall i \in I \\ 1 &\leq u_i \leq 4 \quad [sL/min] & \forall i \in I \end{aligned} \quad (4.30)$$

A [Figura 13](#) mostra os valores da função objetivo e do ponto ótimo de injeção de ar para os três cenários.

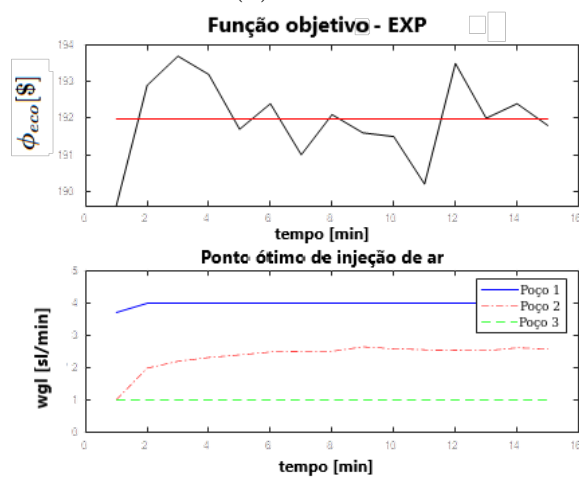
No primeiro cenário os três poços possuem a mesma capacidade de produção, cada poço tem as mesmas condições de operação e o mesmo custo de produção. Os poços 1 e 2



(a) Cenário 1



(b) Cenário 2



(c) Cenário 3

Figura 13 – Comparação da função objetivo e do ponto ótimo de injeção de ar para os três cenários estudados utilizando a MPA.

dividem o ar com vazão média de 3.2 sL/min, enquanto o último poço fica no limite inferior da restrição de 1 sL/min de injeção de ar. Verificando o equipamento experimental foi notado que essa parte recebia uma menor vazão de água da bomba e, por isso, não atingiu

o mesmo nível de produção dos demais, uma explicação mais aprofundada é descrita no apêndice B.

Já no segundo cenário, em que há uma leve diferença no custo associado à injeção de ar, nota-se que há uma menor competição entre o poço 1 e 2, sendo que o primeiro poço, com o menor custo de injeção de ar, obteve uma vazão média de 3.6 sL/min, o segundo ,2.8 sL/min, e o terceiro usa apenas o mínimo de ar.

Neste cenário há um erro, que já foi corrigido nas próximas análises, em que aos 11 minutos o valor da função objetivo e os valores de vazão vão visualmente para os valores mínimos, isso ocorre porque não houve a detecção do estado estacionário e da forma que havia sido programado esses valores eram zerados visualmente. Porém na aplicação real, quando não havia detecção do estado estacionário o sistema não se alterava. isso foi um erro na confecção desse gráfico e foi ajustado nos gráficos posteriores.

Por último, quando há uma grande diferença no preço da injeção de ar, nota-se que o poço 1 atinge o limite superior de injeção de ar, 4 sL/min, o poço 3 o limite inferior e o poço 2 utiliza do ar restante, 2.5 sL/min, para produzir mais.

Esses resultados foram obtidos com a aplicação da MPA no equipamento experimental e não há garantias de que os valores sejam o ótimo real. Para verificar isso, foi realizado um estudo do sistema, nas mesmas condições de operação, em que diversos pontos de operações foram testados e a função objetivo calculada para cada ponto de operação. Em outras palavras, uma busca heurística do ponto ótimo de operação dos poços do sistema

A [Figura 14](#) mostra diferentes condições de operação de injeção de ar testadas, a cada 3 minutos a condição de operação muda.

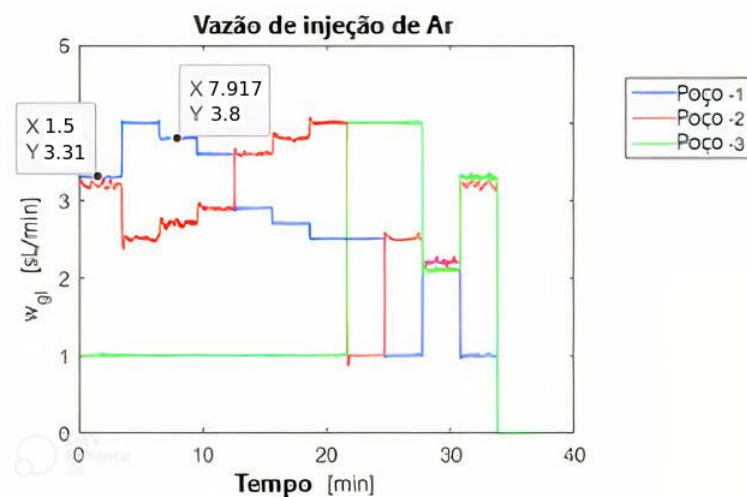
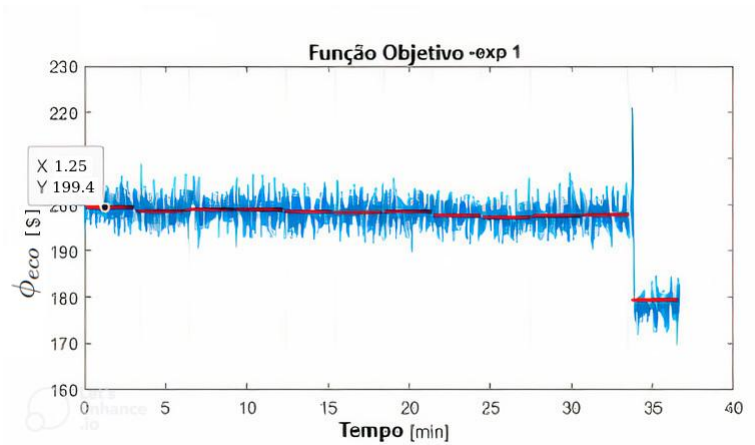
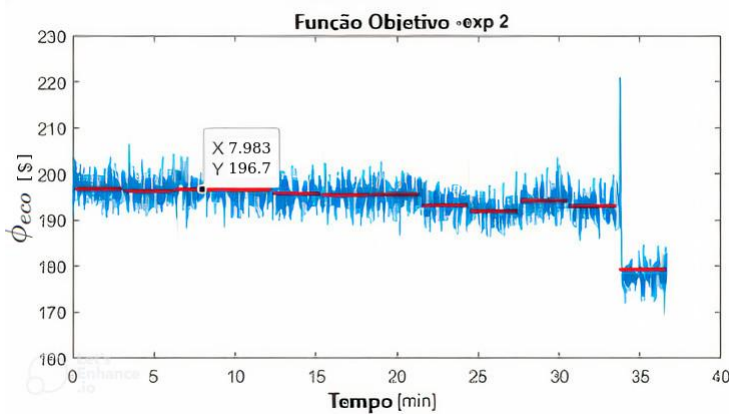


Figura 14 – Vazão injeção de ar utilizados no estudo de ponto ótimo para os três cenários estudados.

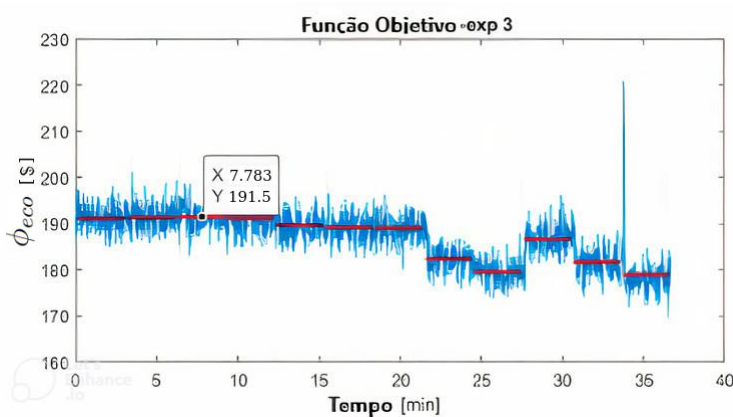
A Figura 15a, a Figura 15b e a Figura 15c mostram os valores das funções objetivos definidas nas Equação 4.27, Equação 4.28 e Equação 4.29, respectivamente, para cada uma das condições da Figura 14.



(a) Funcão objetivo - experimento 1



(b) Funcão objetivo - experimento 2



(c) Funcão objetivo - experimento 3

Figura 15 – Estudo do ponto ótimo de cada cenário pelo cálculo da função objetivo em diferentes vazões de injeção de ar.

Os pontos indicados nas Figura 15a, Figura 15b e Figura 15c são os intervalos em que a função objetivo obteve maior valor durante as diferentes condições, na Figura 14 esses pontos também são representados. O experimento 1 obteve maior valor no primeiro

intervalo enquanto o 2 e o 3, no terceiro intervalo. Associando isso com a [Figura 14](#), o primeiro experimento teve valor ótimo com uma injeção de aproximadamente 3.3 sL/min para os poços 1 e 2 e 1 sL/min para o poço 3. Já os outros experimentos tiveram um valor ótimo de 3.8 sL/min de injeção de ar para o poço 1, 2.7 sL/min para o poço 2 e 1 sL/min para o último poço.

Comparando os três cenários estudados, [Figura 13](#), com a análise do ponto ótimo do sistema por uma busca em diferentes condições de operação do experimento, [Figura 14](#), verifica-se que os pontos de ótimo proveniente da MPA e os ótimos reais do experimento são próximos. Isso demonstra que a RTO pelo método MPA apresenta uma boa estimativa da produção ótima do poço em diferentes cenários e é um indicativo que a otimização está funcionando. Evidentemente os valores não foram exatamente iguais, pois há ocorrência de ruídos nas medidas do experimento e a diferença entre o ótimo e as outras condições de operação é muito próxima dificultando a caracterização do ponto ótimo.

## 4.6 Comparação MPA e ROPA-EKF

Neste estudo foi realizada a comparação entre a MPA e a ROPA utilizando o estimador EKF. Foram realizados dois experimentos independentes, um com a MPA e outro com a ROPA. A [Figura 16](#) apresenta o perfil de distúrbio utilizado nos experimentos, o distúrbio foi gerado pela variação da abertura da válvula ( $vo$ ) que controla a vazão do poço. Foram utilizados apenas dois poços na análise devido a problemas técnicos com o experimento.




Figura 16 – Perfil de distúrbio para a comparação MPA e ROPA-EKF.

A [Equação 4.27](#) foi selecionada como a função objetivo a ser utilizada na RTO. Ambos os poços tiveram a injeção de ar inicial de  $w_{gl}^{inicial} = 2.5$  sL/min, sendo  $w_{gl}^{max} = 4$  sL/min o máximo em cada poço, e a máxima quantidade de ar injetável no sistema dada por  $\sum_{i=1}^2 w_{gl,i} = 5$  sL/min. Além disso, para a ROPA foi utilizado um tempo entre ciclos ( $\Delta T^{ROPA}$ ) de 10 segundos.

Antes de comparar os parâmetros, a [Figura 17](#) apresenta as medidas de vazões sobre as quais a etapa de detecção de estado estacionário foi realizada e se houve a detecção ou não desse estado. O sistema é considerado em estado estacionário quando ambos os poços estão em estado estacionário.

Nota-se que entre 8 e 10 minutos, na [Figura 16](#), o sistema deveria ser considerado não estacionário, pois a abertura de válvula do poço 1 está variando, porém ao analisar a [Figura 17](#) a detecção nesse período foi de estado estacionário. O inverso ocorre em outros momentos em que o sistema deveria ser estacionário, mas a detecção indica o contrário.

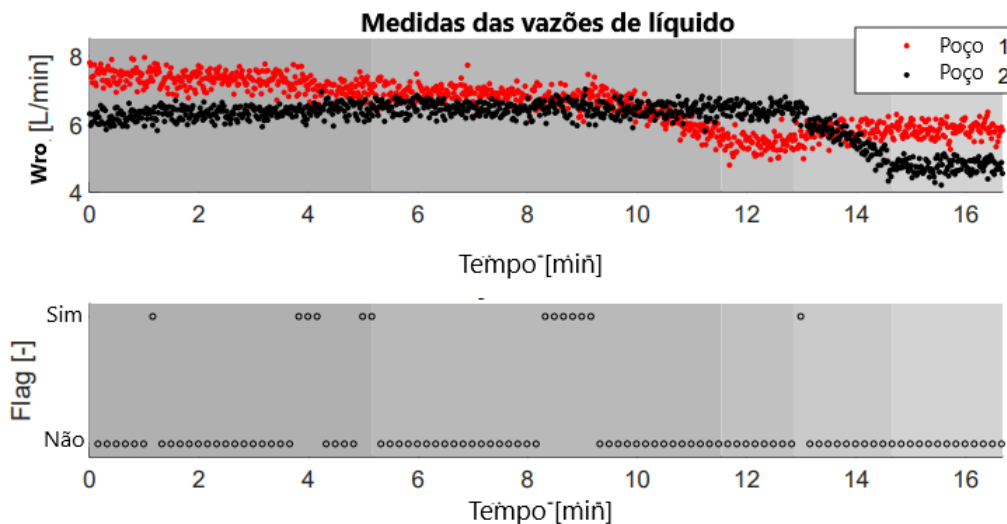


Figura 17 – Detecção de Estado Estacionário. A variável Flag indica se durante a etapa de detecção de estado estacionário o sistema foi considerado estacionário (Sim) ou não estacionário (Não).

Visualmente percebe-se que as medidas são muito próximas, mesmo com a variação da abertura de válvula, e isso dificulta a identificação precisa dos estados estacionários. A consequência é que a MPA em diversos momentos não será aplicada pois o sistema não indicou a estacionariedade corretamente e o sistema não será otimizado, ou então a otimização em tempo real ocorrerá em momentos não estacionários e a estimação dos parâmetros, e por consequência a otimização, será subótima. É uma das grandes vantagens da ROPA é justamente contornar esse problema pelo uso de estimadores *online* que permitem que a ROPA estime os parâmetros adequadamente em qualquer momento, seja estacionário ou não, e assim otimize o sistema mais eficientemente que a MPA ao longo do tempo.

Vale ressaltar que a otimização em não estacionariedade pela ROPA ainda será subótima pois a otimização é feita com um modelo estacionário e apenas os parâmetros utilizados na otimização são estimados com as medidas transientes. Porém a otimização ocorrerá com mais frequência em relação à MPA, já que o sistema não terá que esperar um momento de estacionariedade para que o sistema seja otimizado.

A comparação entre os parâmetros estimados da MPA e ROPA está apresentada na [Figura 18](#). Por questões de visualização, toda vez que o sistema não identifica o estado estacionário para a metodologia MPA, o parâmetro é zerado graficamente. Na realidade durante o experimento nem existe a estimação dos parâmetros nesses momentos, pois o

MPA não atua se não houver estacionariedade. Nota-se que estimação de parâmetros está consistente entre as duas análises.

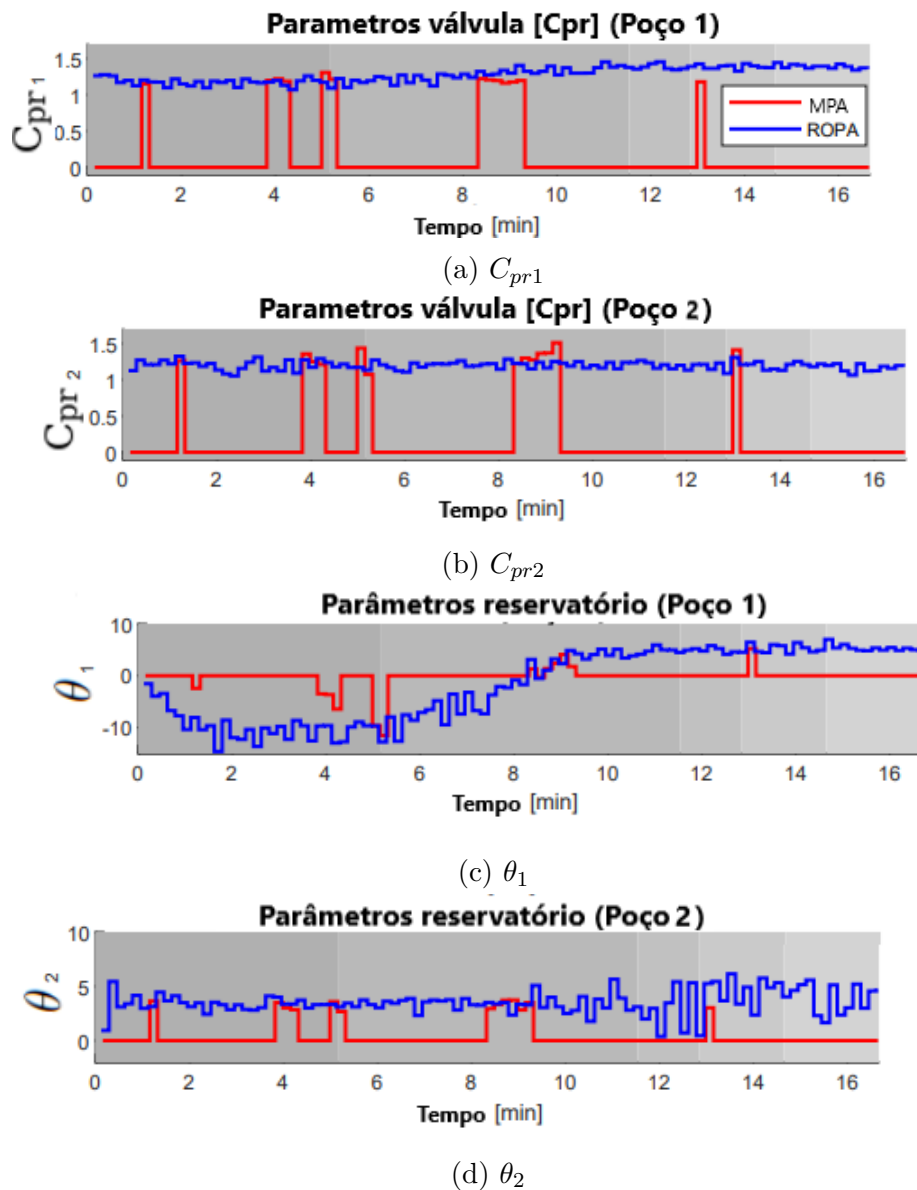


Figura 18 – Comparação da estimativa dos parâmetros da válvula e do reservatório para os métodos ROPA-EKF e MPA.

Com os parâmetros estimados, o sistema foi otimizado e o perfil de injeção de gás foi traçado para as duas metodologias estudadas. Quando a MPA não executava, os parâmetros não eram estimados e o último valor de injeção de ar era mantido constante. A Figura 19 mostra a comparação entre os dois perfis, pode-se notar que o perfil da ROPA consegue acompanhar o estado transiente do sistema enquanto a MPA realiza apenas três otimizações entre os 8 e 14 minutos.

Apesar da diferença entre os dois métodos, o comportamento físico de ambos corresponde ao esperado. No começo o poço 1 possui maior abertura de válvula, ou seja, maior vazão e com isso a injeção de ar não é tão eficiente, pois necessita de mais ar para

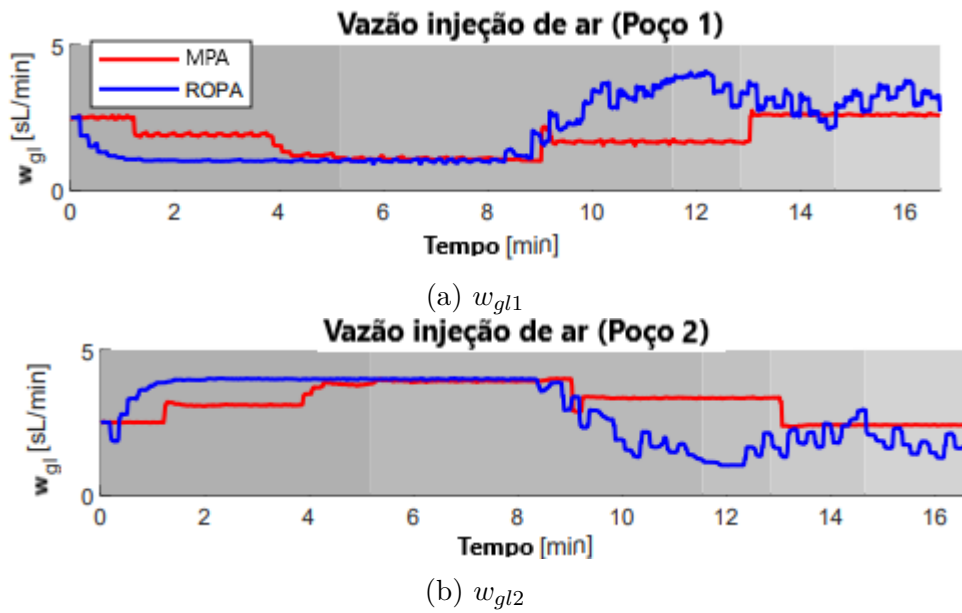


Figura 19 – Comparação do ponto ótimo de injeção de ar entre ROPA-EKF e MPA.

que a densidade da mistura seja menor e o efeito da queda de pressão hidrostática aumente a obtenção de produto em relação a uma vazão menor. À medida que a abertura do poço 1 diminui, a injeção de ar aumenta nesse poço e diminui no poço 2. No final, quando os dois poços atingem condições de operação parecidas e a vazão máxima de gás é dividida igualmente entre os poços, eles competem entre si pelo ar do sistema.

#### 4.6.1 Resultados da comparação entre MPA e ROPA-EKF

##### 4.6.1.1 Análise do lucro da MPA e da ROPA no equipamento experimental

Enfim, foi realizada a comparação em relação à função objetivo, como apresentado na Figura 20. Nessa análise foi realizado mais um experimento em que a vazão de injeção de ar foi dividida igualmente entre os poços, valor inicial de  $w_{gl}^{inicial} = 2.5sL/min$ , representando uma situação em que não temos nenhuma informação sobre a operação dos poços e a decisão mais razoável seria dividir o ar igualmente entre os poços. Assim compara-se as RTO em relação a uma situação não otimizada.




Figura 20 – Comparação do lucro considerando a ROPA-EKF, a MPA e o valor fixo.

Três análises foram realizadas para avaliar o lucro entre os diferentes experimentos.



A primeira compara o lucro do experimento utilizando a MPA e o lucro do experimento utilizando a injeção de ar fixa. A segunda compara o lucro da ROPA em relação à injeção de ar fixa. E a terceira compara lucro da ROPA em relação à MPA.

A [Figura 21](#) apresenta a diferença de lucro em porcentagem a cada instante para as duas primeiras análises, sendo a referência o lucro do experimento utilizando a injeção de ar fixa.

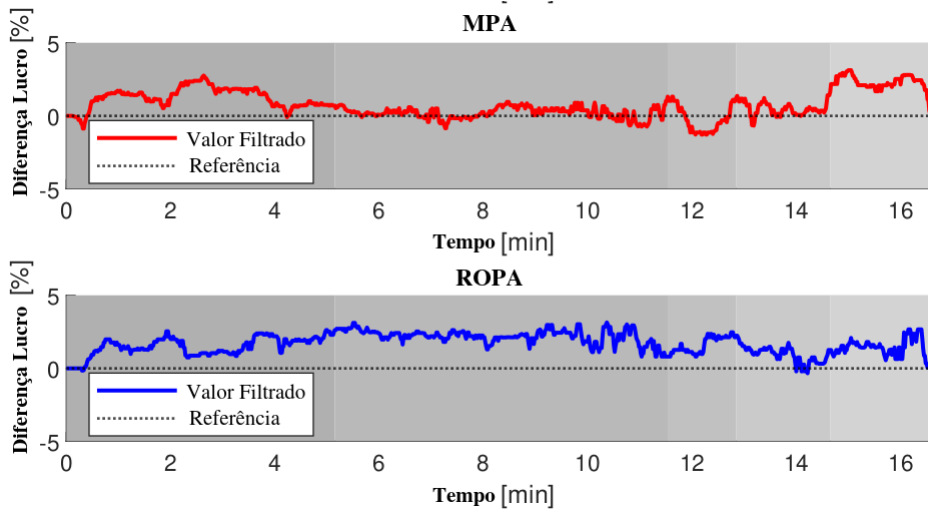


Figura 21 – Diferença de lucro entre as RTO e o experimento fixo.

O valor da diferença de lucro instantâneo em porcentagem entre as RTO e a injeção de ar fixa foi feito utilizando a [Equação 4.31](#).

$$100 * \frac{\phi(t) - \phi_{fixo}(t)}{\phi_{fixo}(t)} \quad (4.31)$$

sendo  $\phi$  o lucro da RTO em determinado instante tempo e  $\phi_{fixo}$  o lucro do experimento com injeção de ar fixo em determinado tempo. Como as medidas do lucro instantâneo são muito ruidosas o valor foi filtrado usando uma média móvel dos pontos do gráfico, considerando um período de 100 segundos.

Em média, o lucro obtido utilizando a ROPA foi melhor em comparação ao caso de vazão constante considerando que o valor da linha de tendência é positivo em quase todo o intervalo e o lucro da MPA também foi maior porém nota-se que em alguns momentos linha de tendência do MPA é quase igual ao valor do caso fixo.

Comparando a MPA e a ROPA na [Figura 21](#) nota-se que entre 4 e 13 minutos o valor da linha de tendência é mais positiva para a ROPA, indicando que a ROPA é mais lucrativa em média em relação à MPA nesse período. Provavelmente por que nesses instantes o sistema está em estado transiente. Já no restante do tempo o valor da linha de tendência entre os métodos tem comportamentos parecidos, porém a MPA teve uma melhor performance em relação à ROPA na análise em estado estacionário. Em suma, a

ROPA mostrou-se eficaz para tratar desse sistema em questão, principalmente quando houve momentos de não estacionariedade .

#### 4.6.1.2 Análise da média do lucro acumulado de 4 experimentos independentes para cada um dos métodos

Para verificar a consistência dos resultados e que a ROPA de fato teve uma performance melhor em relação à MPA foi realizado uma análise quantitativa sobre os lucros obtidos. Para isso foi obtido o valor de lucro acumulado para 4 experimentos independentes e idênticos em cada um dos métodos e a média e o desvio padrão dos lucros acumulados foram calculados. Isso permite verificar se em múltiplos experimentos a otimização pela ROPA continua mais lucrativa que otimização pela MPA. A [Tabela 1](#) mostra que a ROPA obteve uma maior média de lucro acumulado, 1% a mais de lucro, e menor variabilidade que a MPA.

Tabela 1 – Média de lucro acumulado de 4 experimentos idênticos e independentes

Método	Média Lucro acumulado [ $10^3$ \$]	Desvio Padrão [ $10^3$ \$]
ROPA	2.0408	0.0347
MPA	2.0203	0.0562

#### 4.6.2 Discussão dos resultados da comparação entre MPA e ROPA-EKF

Avaliando a [Tabela 1](#), a ROPA-EKF demonstrou ser um pouco mais eficiente obtendo uma média de lucro acumulado 1% maior em relação à MPA e um menor desvio padrão. Apesar deste resultado não ser tão expressivo e depender muito da função objetivo escolhida, nota-se que a ROPA teve uma performance superior ao MPA entre 4 a 13 minutos, justamente em momentos em que o sistema não estava em estado estacionário, e nos momentos restantes teve uma performance um pouco inferior.

A boa performance da ROPA na representação do sistema em estado não estacionário pode ser notado na [Figura 18c](#), em que a estimação do parâmetro  $\theta$  do poço 1 pela ROPA tem um perfil bem parecido com o perfil de distúrbios da [Figura 16](#). Tanto a dinâmica de transição do ponto inicial ao primeiro ponto ótimo como o distúrbio do primeiro poço entre 5 a 11 minutos são bem estimados pela ROPA, enquanto a MPA tem dificuldade em identificar os estados estacionários entre 0 a 5 minutos e de acompanhar as mudanças entre 5 a 11 minutos. E até quando os dois poços ficam em estado estacionário, 15 minutos em diante, a ROPA tem uma estimação muito parecida com a da MPA.

Isso se reflete nos resultados apresentados na [Figura 19](#) em que a ROPA está sempre buscando o ponto ótimo de injeção de ar, enquanto a MPA demora para atuar no

experimento, e mesmo em estado estacionário a ROPA tem um ponto ótimo semelhante à MPA. Demonstrando o quão eficiente foi a aplicação da ROPA nesse sistema experimental em relação à MPA, especialmente quando o sistema não estava em estado estacionário. Mostrando que de fato uma das grandes vantagens da ROPA é sua capacidade de otimizar sistemas dinâmicos em tempo real.

## 4.7 Avaliação do custo de chegada do MHE

Após comparar e discutir os resultados apresentados na comparação da ROPA -EKF e MPA, o próximo estudo será sobre a diferença de performance da ROPA utilizando os estimadores *online* MHE e EKF. Porém antes de comparar a ROPA-MHE e a ROPA-EKF, será realizado um estudo sobre a influência do custo de chegada ( $\Gamma$  na [Equação 3.22](#)) na estimação do MHE.

Para verificar a influência do custo de chegada na estimação do MHE foram estimadas as medidas de  $w_{ro}$  e  $P_{rh}$  utilizando o MHE sem o custo de chegada e com o custo de chegada sobre o modelo dinâmico.

Diferentemente dos estudos de RTO, que foram feitos utilizando o equipamento experimental, este estudo foi simulado fixando os valores dos parâmetros a serem estimados  $\theta$  e  $C_{pr}$  no modelo dinâmico, calculando as medidas para uma condição inicial e uma injeção de ar predefinida e adicionando um ruído gaussiano sobre essas medidas calculadas para simular o comportamento da planta. Foram simuladas três situações variando os valores de  $\theta$  e  $C_{pr}$ , segundo a [Tabela 2](#). Também foi simulado um distúrbio, alterando-se o valor da injeção de ar na metade da simulação, para verificar o comportamento do MHE em relação a distúrbios no modelo. Os parâmetros foram escolhidos como valores próximos do estimado no experimento de comparação da ROPA e MPA, valores após 12 minutos na [Figura 18](#).

Tabela 2 – Parâmetros do modelo a serem estimados utilizados nas simulações

Exp	$\theta$	$C_{pr}$
1	4.846	1.83
2	4.846	1.53
3	5.846	1.53

O estudo foi feito considerando uma janela de tamanho fixo contendo 8 medidas, sendo a primeira janela no instante de tempo 0. O custo de chegada foi considerado a partir da primeira janela, ou seja, simulando medidas passadas ao instante 0. Na primeira janela foram utilizadas estimativas de estados e parâmetros iniciais para o cálculo do custo de chegada pelo EKF, a partir da segunda janela em diante os valores de estados e parâmetros da janela anterior eram utilizados no cálculo do custo de chegada. A [Figura 22](#) apresenta o primeiro caso, os outros cenários estudados são apresentados no Apêndice C.

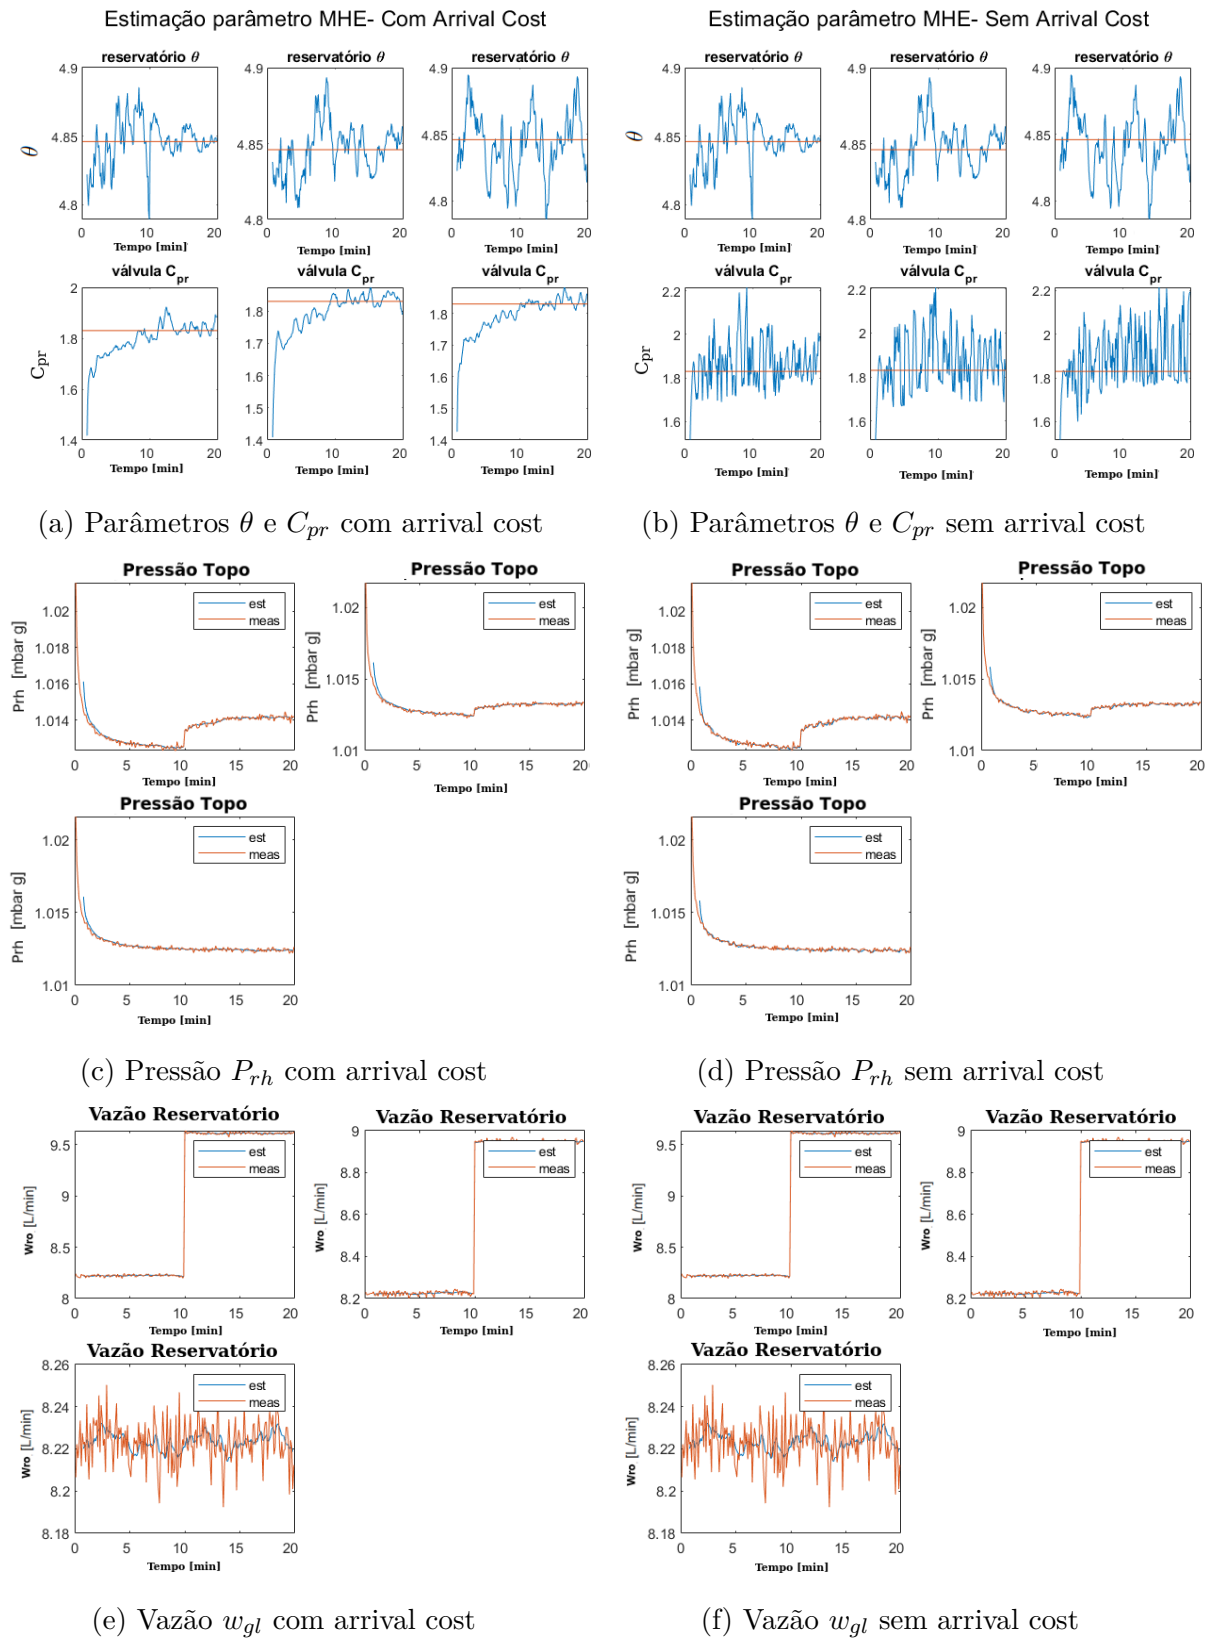


Figura 22 – Estimação MHE para o experimento 1: Parâmetros, Pressão, Vazão.

Para o primeiro caso, nota-se que a estimação do parâmetro  $\theta$  não sofre alterações com o uso do custo de chegada e consegue estimar com desvio em torno de 1% em relação

ao parâmetro original. Já a estimativa do  $C_{pr}$  com o custo de chegada acompanha o comportamento esperado pelo gráfico de Pressão, [Figura 22c](#), e tem desvios em torno de 5%, enquanto sem o termo do custo de chegada o parâmetro se mantém perto do valor esperado porém com muitas oscilações. O comportamento descrito neste caso é parecido nas outras simulações.

Para comparar a influência do custo de chegada, a [Tabela 3](#) mostra a média e desvio padrão de cada poço nos 3 experimentos realizados, considerando os últimos 7 minutos da simulação. Foi escolhido essa região para comparação, pois, visualmente pela [Figura 22](#), os parâmetros já convergiram em uma região estacionária da simulação, que não apresenta variação pela dinâmica do modelo, tornando mais simples a comparação entre os parâmetros estimados. O asterisco indica que não foi utilizado o custo de chegada.

Tabela 3 – Média e desvio padrão para os últimos 70 pontos da análise da estimação de parâmetros pelo MHE com ou sem o custo de chegada

Exp	poço	parâmetro	média	desvio padrão	média*	desvio padrão*
1	$\theta$	1	4.846	0.006	4.846	0.006
		2	4.845	0.011	4.845	0.011
		3	4.843	0.023	4.843	0.023
	$C_{pr}$	1	1.84	0.02	1.86	0.07
		2	1.84	0.02	1.86	0.10
		3	1.84	0.02	1.92	0.14
2	$\theta$	1	4.846	0.006	4.846	0.006
		2	4.845	0.011	4.845	0.011
		3	4.843	0.023	4.843	0.023
	$C_{pr}$	1	1.54	0.02	1.55	0.05
		2	1.54	0.01	1.56	0.09
		3	1.54	0.01	1.61	0.11
3	$\theta$	1	5.847	0.007	5.847	0.007
		2	5.848	0.011	5.848	0.011
		3	5.842	0.021	5.842	0.021
	$C_{pr}$	1	1.54	0.03	1.56	0.08
		2	1.54	0.02	1.58	0.11
		3	1.54	0.02	1.63	0.13

Analisando a tabela verifica-se que a diferença entre o uso ou não do custo de chegada na média e desvio padrão do parâmetro  $C_{pr}$  é relevante, indicando a importância do custo de chegada para esse termo. Porém isso não ocorre tão significativamente com o  $\theta$ . Como o custo de chegada é um valor que considera as informações passadas, pode ter ocorrido que seu peso tenha sido insuficiente na estimação do  $\theta$  e os valores passados tenham sido negligenciados e por isso o comportamento esteja tão parecido com e sem o custo de chegada. Enquanto no  $C_{pr}$  acontece o inverso e o custo de chegada tem um peso suficiente para que os estados passados afetem a estimação. Apesar dessas questões, a estimação com o custo de chegada forneceu uma estimativa razoável dos parâmetros e

teve menor desvio padrão, por isso, e pela grande influência que esse termo pode ter na estimação, foi decidido considerar o custo de chegada no equacionamento e implementação do MHE no equipamento experimental.

Outra questão importante é que o custo de chegada foi analisado para cenários simulados e deve ser avaliado como o MHE estimará os parâmetros no equipamento experimental. Porém é esperado que os resultados obtidos na simulação sejam adequados ao equipamento experimental, uma vez que o modelo utilizado aproxima bem o comportamento real do sistema. Assim, para a implementação do ROPA-MHE, o custo de chegada no equipamento experimental terá os mesmo parâmetros de sintonia da simulação.

## 4.8 Comparação ROPA-MHE e ROPA-EKF

Para a comparação entre a ROPA utilizando MHE e a ROPA utilizando o EKF foi considerada a mesma condição inicial da seção 4.5.3, porém a análise foi realizada com 3 poços. O perfil de distúrbio é apresentado na [Figura 23](#).




Figura 23 – Perfil de distúrbio para comparação entre ROPA utilizando o EKF e o MHE.

A comparação entre os parâmetros está apresentada na [Figura 24](#). Ambos métodos tiveram estimativas semelhantes, indicando que a princípio os parâmetros de sintonia do custo de chegada estavam adequado à estimação do MHE no equipamento experimental.

Apesar disso houve uma diferença visível na estimação do parâmetro da válvula do segundo poço, podendo estar relacionado ao cálculo do custo de chegada. Porém analisando o perfil de pressão na [Figura 25](#) nota-se que há uma leve diferença nas medidas do segundo poço entre os experimentos utilizando o MHE e o EKF e, por se tratarem de experimentos independentes, é mais provável que a diferença seja por mudanças no comportamento das variáveis entre experimentos do que pelo cálculo do custo de chegada que se mostrou apropriado para os outros dois poços.

Apesar da diferença de valores na estimação de parâmetros, o perfil de injeção de ar, [Figura 26](#), não apresenta diferenças ao longo da otimização da ROPA-MHE e ROPA-EKF.

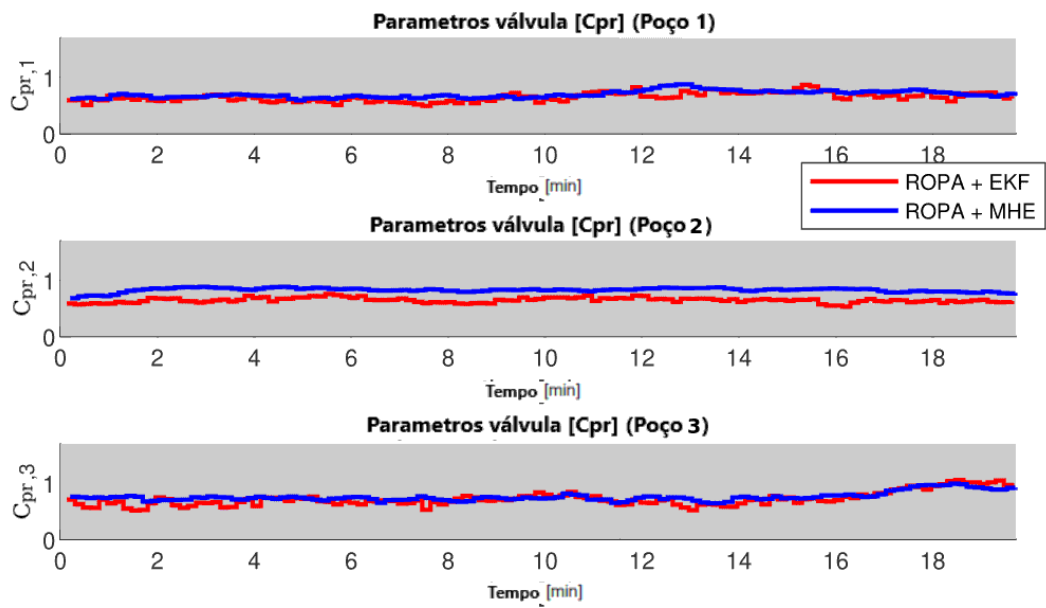
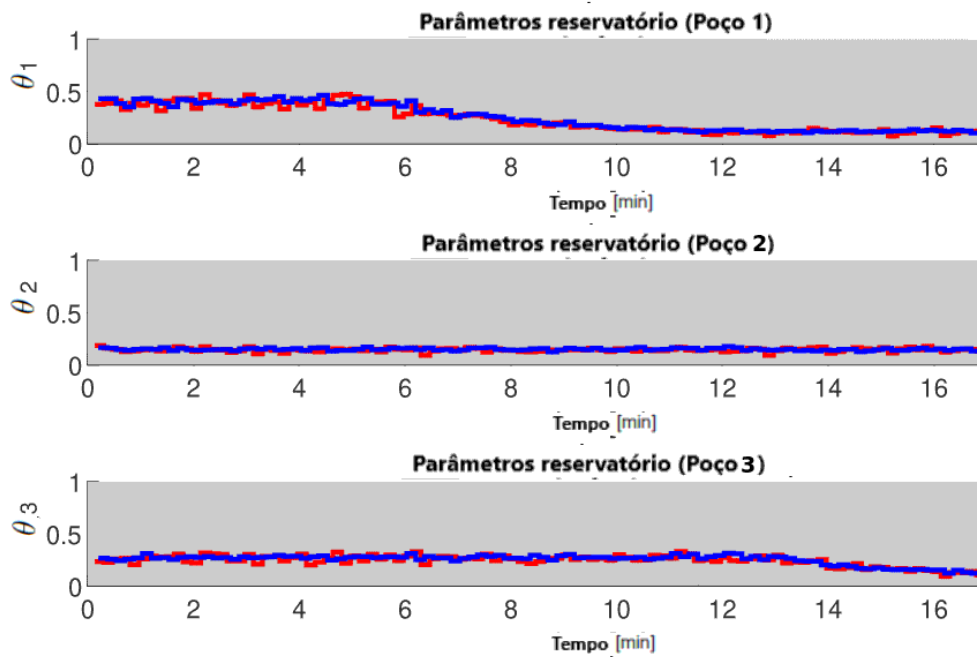
(a)  $C_{pr}$ (b)  $\theta$ 

Figura 24 – Perfil dos parâmetros estimados para o ROPA utilizando o MHE e o EKF.

#### 4.8.1 Resultados da comparação entre ROPA-MHE e ROPA-EKF

Também foi realizada a análise econômica utilizando a mesma premissa da comparação da MPA e a ROPA-EKF, ou seja, há uma condição em que a injeção de ar é

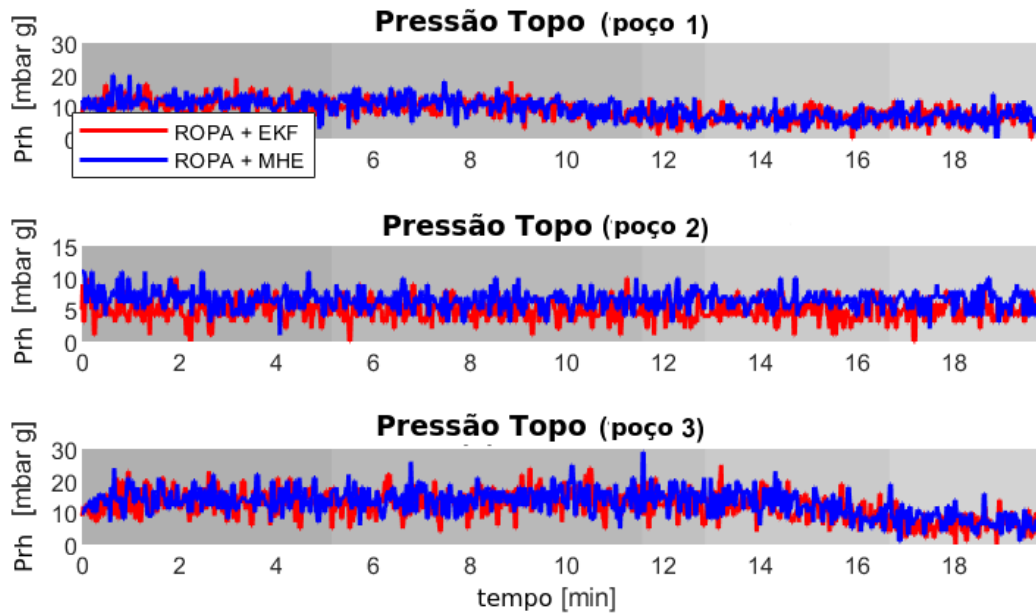


Figura 25 – Perfil de pressão do topo obtida com os medidores de pressão localizados no topo do experimento.




Figura 26 – Comparação do perfil de injeção de ar entre o ROPA-EKF e o ROPA-MHE.

mantida constante no valor inicial de  $w_{gl}^{inicial} = 2.5sL/min$  para representar uma situação não otimizada. Porém nessa análise modificou-se a função objetivo do sistema, sendo o custo de injeção de ar desconsiderado e o fator de custo para cada poço modificado segundo

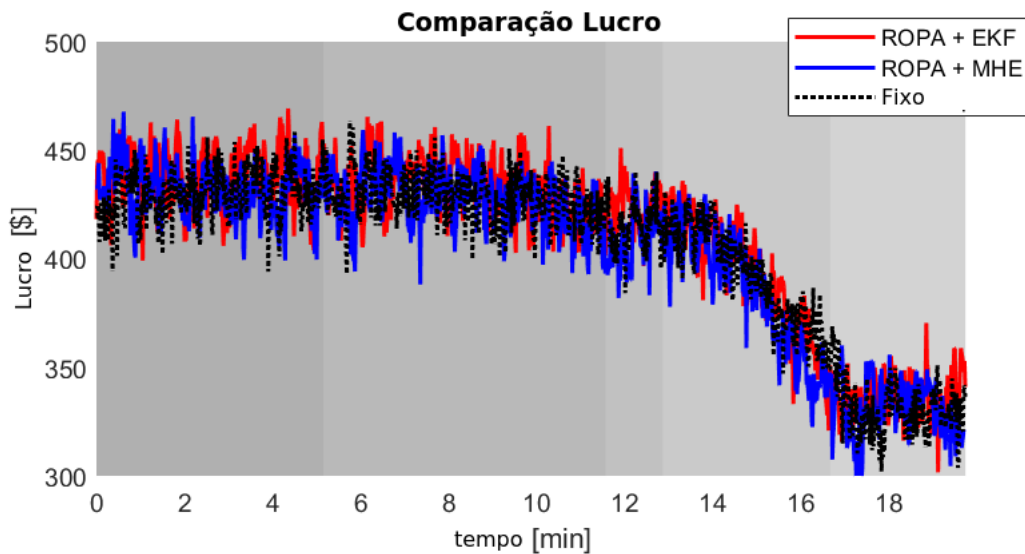


a Equação 4.32.

$$\phi_{eco} = 20w_{ro,1} + 10w_{ro,2} + 30w_{ro,3} \quad (4.32)$$

A modificação na função objetivo permite avaliar o comportamento da ROPA considerando somente a obtenção de líquido proveniente do reservatório, simplificando a análise econômica do sistema. Foi decidido retirar o custo de injeção de ar do equacionamento pois, dependendo dos custos associados, poderia penalizar fortemente a função objetivo, dificultando a interpretação do lucro entre experimentos. Além disso essa mudança deixaria a função objetivo consistente com o trabalho de Matias et al (2022), que utilizam o mesmo equipamento e as mesmas condições de operação, permitindo comparações com o trabalho realizado pelos autores.

A Figura 27 compara o valor da função objetivo em cada instante de tempo para cada um dos experimentos. Nota-se que na maioria do tempo a utilização da ROPA, seja com EKF ou MHE, tem resultados melhores que o uso de uma injeção de ar fixa.



9

Figura 27 – Comparação de lucro entre o ROPA-EKF, ROPA-MHE e a injeção de ar fixa

A Figura 28 compara o lucro acumulado pela ROPA-EKF e a ROPA-MHE. A ROPA-EKF obteve um lucro acumulado 1% maior que a ROPA-MHE,

#### 4.8.2 Discussão dos resultados da comparação entre ROPA-MHE e ROPA-EKF.

Assim como na seção de resultados da comparação MPA e ROPA-EKF, a diferença de lucro entre os métodos foi de 1%. Entretanto nesse estudo foi utilizada outra equação objetivo e o experimento foi realizado usando três poços. Assim não é possível comparar os resultados da otimização entre os dois estudos. Mas analisando a Figura 24 nota-se

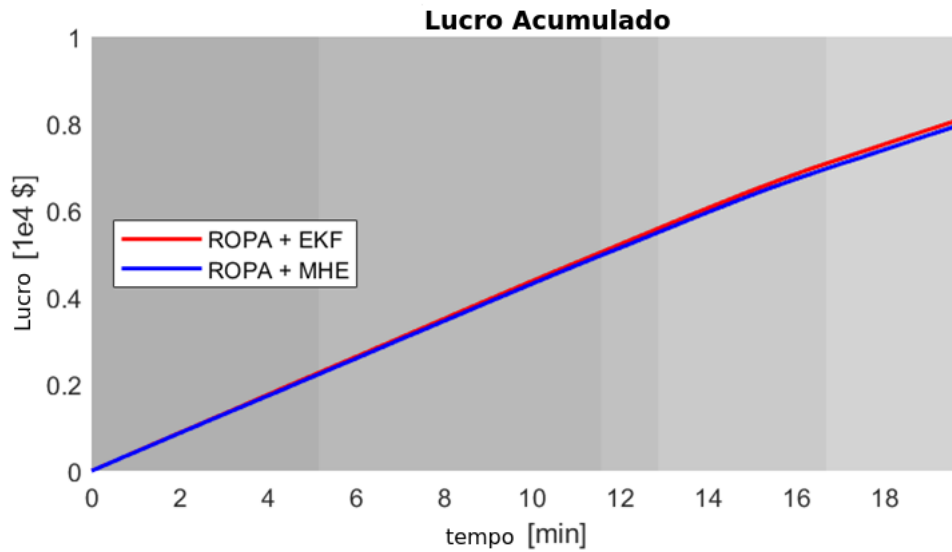


Figura 28 – Comparação do lucro acumulado entre a ROPA-MHE e ROPA-EKF.

que a diferença na estimação de parâmetros entre a ROPA-MHE e ROPA-EKF é muito pequena, diferentemente da apresentada no estudo entre ROPA-EKF e MPA.

Considerando o trabalho realizado por Matias et al (2022) em que fizeram a comparação do lucro entre a ROPA-EKF e a MPA, resultados na Figura 29, pode-se perceber que a diferença de lucro entre o uso da ROPA em relação à MPA é notável para a função objetivo adotada. Sendo possível inferir que a diferença entre a ROPA-EKF e a ROPA-MHE não é significativa.




Figura 29 – Comparação do lucro acumulado em porcentagem entre a ROPA-EKF e MPA. A linha azul é relacionada a outra análise realizada pelos autores e deve ser desconsiderada na interpretação dessa imagem. (Adaptado de Matias et al 2022)

Isso mostra que a implementação da ROPA com o MHE teve uma boa performance na estimação, sendo nesse sistema um pouco inferior ao EKF, e que a ROPA tem flexibilidade para utilizar diferentes estimadores *online*. Porém vale ressaltar que nesse sistema o uso do EKF como estimador foi superior tanto na performance quanto na facilidade de implementação, além de ter um custo computacional menor por ser uma estimação recursiva.

Isso pode ser explicado pelo fato do EKF ser muito eficiente em vários sistemas não

lineares com exceção dos altamente não lineares, que podem ter pontos de singularidades ou próximos da singularidade fazendo com que o cálculo das derivadas parciais não existam ou causem aproximações não muito precisas da média e da variância (SCHEI, 2007), e pelo perfil da dinâmica do experimento nota-se que o sistema tem um comportamento pouco não linear, ou seja, não há variações bruscas ao longo do tempo.



## 5 Conclusão

Esta dissertação tinha como objetivo implementar a ROPA em um sistema físico, compará-la com a MPA e depois aplicar outro tipo de estimador *online* para verificar a viabilidade da ROPA, e possíveis vantagens operacionais, com uso de outro estimador. Para isso, foram realizadas as etapas de implementação, validação e verificação da MPA no equipamento experimental. Os resultados obtidos mostraram que o sistema está adequadamente caracterizado pelo modelo proposto e que a MPA consegue localizar satisfatoriamente os pontos de operação ótimo para diferentes condições.

Também foram realizadas a implementação e análise da ROPA utilizando o estimador EKF. O perfil de injeção de gás da ROPA-EKF mostrou-se eficaz para acompanhar a dinâmica do experimento na ocorrência de distúrbios, enquanto a MPA apresenta dificuldade de identificar se o sistema está em estado estacionário ou não. Assim, a implementação da ROPA-EKF em um sistema experimental físico, ou seja não simulado, foi bem sucedida e além disso obteve uma performance melhor que a da MPA. Isso era esperado devido a natureza dos distúrbios afetando o experimento.

Em seguida, foi realizada uma simulação da estimação de parâmetros do MHE no modelo dinâmico e notou-se que o estimador consegue estimar os parâmetros com precisão ao considerar o termo de custo de chegada. Apesar disso, o ajuste desse termo pode afetar a estimação dos parâmetros de maneira significativa, podendo não ser adequado para o experimento físico, mas durante a implementação da ROPA-MHE no equipamento experimental o termo do custo de chegada utilizado na simulação mostrou-se apropriado e não foi alterado.

Por último foi realizado a comparação da ROPA-EKF com a ROPA-MHE. Ambos os métodos tiveram perfis semelhantes na estimação de parâmetros, conseguindo acompanhar a dinâmica do sistema adequadamente, e em consequência a otimização entre os métodos também foi muito parecida.

No final todos os objetivos foram alcançados. A ROPA mostrou-se aplicável ao sistema experimental proposto e teve boa performance na otimização em tempo real durante estados transientes sem alterar a performance em estados estacionários. A ROPA obteve resultados melhores que o método de RTO mais utilizado, a MPA, e foi flexível na implementação de diferentes estimadores *online*, EKF e MHE. Por outro lado, a ROPA-MHE não apresentou melhoras nos resultados e, por utilizar uma estimação não recursiva baseada em otimizações, tem uma implementação mais complexa e um custo computacional muito maior em relação à ROPA-EKF, que utiliza estimação recursiva. Sendo a utilização do EKF mais adequada ao experimento, mas o MHE também obteve

bons resultados e pode ser utilizado na ROPA.

Considerando todas as análises realizadas nesta dissertação, a ROPA é um método de RTO de fácil implementação, muito semelhante à MPA, e que pode ser utilizado em equipamentos reais. Além disso a ROPA apresentou bons resultados em relação à MPA, especialmente em períodos transientes, e mostrou-se flexível no uso de diferentes estimadores na etapa de estimação, permitindo se adaptar a diferentes necessidades. Assim, a ROPA mostrou ser um método promissor na aplicação industrial, considerando que o processo tenha um modelo dinâmico, e esta dissertação conseguiu contribuir para o desenvolvimento da ROPA.

## 6 Sugestões para estudos futuros

- Conclusões relevantes podem ser obtidas tanto a partir do teste da performance da ROPA em diferentes cenários como aplicações em sistemas de larga escala, quanto a partir do estudo do uso de diferentes estimadores *online* em situações onde o EKF não seja o mais adequado, trazendo uma melhor visão para a aplicabilidade do método.
- Responsável por determinar o tempo entre ciclos da ROPA, o termo  $\Delta T^{ROPA}$  pode ter influência tanto na performance quanto na estabilidade da aplicação do referido método no sistema, pois intervalos grandes entre aplicações da ROPA podem afetar a eficiência da otimização e pequenos intervalos podem desestabilizar o sistema, já que a otimização é em estado estacionário mas a estimação em estado transiente. Portanto, se faz interessante compreender seus efeitos na otimização em tempo real do sistema.
- Uma das grandes desvantagens da aplicação da ROPA no contexto industrial é a dificuldade na obtenção de modelos dinâmicos de processos. Assim estudos envolvendo a aproximação de modelos dinâmicos podem contribuir no desenvolvimento da ROPA.
- A exploração de cenários onde há incertezas com relação ao comportamento de variáveis, pode ser realizada através da implementação de ROPA robusto, onde é considerada a otimização estocástica na fase de otimização para obtenção do ótimo operacional e também a adaptação dinâmica considerando a função densidade de probabilidade, utilizando métodos como por exemplo o filtro de partículas (*particle filter*), na fase de estimação das variáveis relevantes.





# Referências

- ALEXANDER, R. et al. Challenges and opportunities on nonlinear state estimation of chemical and biochemical processes. *Processes*, v. 8, n. 11, 2020. ISSN 2227-9717. Citado na página [26](#).
- ARASARATNAM, I.; HAYKIN, S. Cubature kalman filters. *IEEE Transactions on Automatic Control*, v. 54, n. 6, p. 1254–1269, 2009. Cited By :1983. Citado na página [34](#).
- BAMBERGER, W.; ISERMANN, R. Adaptive on-line steady-state optimization of slow dynamic processes. *Automatica*, Elsevier, v. 14, n. 3, p. 223–230, 1978. Citado na página [23](#).
- BAYES, T. An essay towards solving a problem in the doctrine of chances. *Phil. Trans. of the Royal Soc. of London*, v. 53, p. 370–418, 1763. Citado na página [26](#).
- BESL, H. et al. Nontraditional optimization for isom unit improves profits. *Oil and Gas Journal*, v. 96, n. 19, 1998. Citado na página [23](#).
- BIEGLER, L. T.; YANG, X.; FISCHER, G. A. G. Advances in sensitivity-based nonlinear model predictive control and dynamic real-time optimization. *Journal of Process Control*, v. 30, p. 104–116, 2015. Cited By :52. Citado na página [27](#).
- BOX, G. E. P. Evolutionary operation: A method for increasing industrial productivity. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, Wiley Online Library, v. 6, n. 2, p. 81–101, 1957. Citado na página [24](#).
- CAO, S.; RHINEHART, R. R. An efficient method for on-line identification of steady state. *Journal of Process Control*, v. 5, n. 6, p. 363–374, 1995. Cited By :171. Citado na página [29](#).
- CHEN, C. Y.; JOSEPH, B. On-line optimization using a two-phase approach: An application study. *Industrial and Engineering Chemistry Research*, v. 26, n. 9, p. 1924–1930, 1987. Cited By :98. Citado na página [19](#).
- CURVELO, R. et al. Investigation of the use of transient process data for steady-state real-time optimization in presence of complex dynamics. In: *Computer Aided Chemical Engineering*. [S.l.]: Elsevier, 2021. v. 50, p. 1299–1305. Citado na página [25](#).
- DARBY, M. L. et al. Rto: An overview and assessment of current practice. *Journal of Process Control*, v. 21, n. 6, p. 874–884, 2011. Cited By :185. Citado 4 vezes nas páginas [13](#), [19](#), [20](#) e [21](#).
- DELOU, P. et al. A real-time optimization strategy for small-scale facilities and implementation in a gas processing unit. *Processes*, v. 9, p. 1179, 07 2021. Citado 2 vezes nas páginas [24](#) e [33](#).
- DIRZA, R.; SKOGESTAD, S.; KRISHNAMOORTHY, D. Optimal resource allocation using distributed feedback-based real-time optimization. *IFAC-PapersOnLine*, v. 54, n. 3, p. 706–711, 2021. ISSN 2405-8963. 16th IFAC Symposium on Advanced Control of Chemical Processes ADCHEM 2021. Citado na página [26](#).

- ELSHEIKH, M. et al. A comparative review of multi-rate moving horizon estimation schemes for bioprocess applications. *Computers Chemical Engineering*, v. 146, p. 107219, 2021. ISSN 0098-1354. Citado na página 39.
- ENGELL, S. Feedback control for optimal process operation. *Journal of Process Control*, v. 17, n. 3, p. 203–219, 2007. Citado na página 23.
- FRANÇOIS, G.; BONVIN, D. Use of transient measurements for the optimization of steady-state performance via modifier adaptation. *Industrial and Engineering Chemistry Research*, v. 53, n. 13, p. 5148–5159, 2013. Citado na página 25.
- FRIEDMAN, Y. Z. What's wrong with unit closed loop optimization? v. 74, n. 10, 10 1995. Citado na página 21.
- GAO, W.; ENGELL, S. Dynamic mawqa: Towards efficient real-time optimization of slow dynamic processes. In: IEEE. *2017 36th Chinese Control Conference (CCC)*. [S.l.], 2017. p. 2893–2898. Citado na página 25.
- GUAY, M.; DOCHAIN, D.; PERRIER, M. Adaptive extremum-seeking control of nonisothermal continuous stirred tank reactors. *Chemical Engineering Science*, Elsevier, v. 60, n. 13, p. 3671–3681, 2005. Citado na página 26.
- HASHEMIAN, N.; ARMAOU, A. Fast moving horizon estimation of nonlinear processes via carleman linearization. In: *2015 American Control Conference (ACC)*. [S.l.: s.n.], 2015. p. 3379–3385. Citado 2 vezes nas páginas 13 e 37.
- HUANG, R.; HARINATH, E.; BIEGLER, L. Lyapunov stability of economically oriented nmpc for cyclic processes. *Journal of Process Control*, v. 21, p. 501–509, 04 2011. Citado na página 19.
- JIANG, T. et al. Application of steady-state detection method based on wavelet transform. *Computers and Chemical Engineering*, v. 27, n. 4, p. 569–578, 2003. Cited By :82. Citado na página 29.
- JULIER, S.; UHLMANN, J. Unscented filtering and nonlinear estimation. *Proceedings of the IEEE*, v. 92, p. 401 – 422, 04 2004. Citado na página 27.
- KALMAN, R. E. A new approach to linear filtering and prediction problems. *Transactions of the ASME–Journal of Basic Engineering*, v. 82, n. Series D, p. 35–45, 1960. Citado na página 26.
- KRISHNAMOORTHY, D.; FOSS, B.; SKOGESTAD, S. Real-time optimization under uncertainty applied to a gas liftedwell network. *Processes*, v. 4, n. 4, 2016. Cited By :29. Citado na página 44.
- KRISHNAMOORTHY, D.; RYU, J.; SKOGESTAD, S. A dynamic extremum seeking scheme applied to gas lift optimization. *IFAC-PapersOnLine*, v. 52, n. 1, p. 802–807, 2019. ISSN 2405-8963. 12th IFAC Symposium on Dynamics and Control of Process Systems, including Biosystems DYCOPS 2019. Citado na página 26.
- LEE, K. S.; LEE, W.-K. On-line optimizing control of a nonadiabatic fixed bed reactor. *AIChE Journal*, Wiley Online Library, v. 31, n. 4, p. 667–675, 1985. Citado na página 23.

LÓPEZ-NEGRETE, R.; BIEGLER, L. T. A moving horizon estimator for processes with multi-rate measurements: A nonlinear programming sensitivity approach. *Journal of Process Control*, v. 22, n. 4, p. 677–688, 2012. ISSN 0959-1524. Citado na página 27.

MARCHETTI, A.; CHACHUAT, B.; BONVIN, D. Modifier-adaptation methodology for real-time optimization. *Industrial and Engineering Chemistry Research*, v. 48, n. 13, p. 6022–6033, 2009. Cited By :167. Citado na página 25.

MATIAS, J. et al. Real-time optimization with persistent parameter adaptation applied to experimental rig. *IFAC-PapersOnLine*, v. 54, n. 3, p. 475–480, 2021. ISSN 2405-8963. 16th IFAC Symposium on Advanced Control of Chemical Processes ADCHEM 2021. Citado na página 29.

MATIAS, J. et al. Steady-state real-time optimization using transient measurements on an experimental rig. *Journal of Process Control*, v. 115, p. 181–196, 2022. ISSN 0959-1524. Citado 4 vezes nas páginas 14, 24, 71 e 72.

MATIAS, J. O. A.; ROUX, G. A. C. L. Real-time optimization with persistent parameter adaptation using online parameter estimation. *Journal of Process Control*, v. 68, p. 195–204, 2018. Cited By :6. Citado 2 vezes nas páginas 13 e 21.

MATIAS, J. O. A.; ROUX, G. A. C. L. Plantwide optimization via real-time optimization with persistent parameter adaptation. *Journal of Process Control*, v. 92, p. 62–78, 2020. Citado 2 vezes nas páginas 21 e 25.

NAYSMITH, M. R.; DOUGLAS, P. L. Review of real time optimization in the chemical process industries. *Developments in Chemical Engineering and Mineral Processing*, v. 3, n. 2, p. 67–87, 1995. Cited By :23. Citado na página 19.

NETO, J.; COSTA, A. A petrobrás e a exploração de petróleo offshore no brasil: um approach evolucionário. *Revista Brasileira de Economia*, v. 61, 02 2006. Citado na página 41.

PHAM, D. T.; VERRON, J.; ROUBAUD, M. C. A singular evolutive extended kalman filter for data assimilation in oceanography. *Journal of Marine Systems*, v. 16, n. 3-4, p. 323–340, 1998. Cited By :359. Citado na página 27.

PRIOR, D.; LOPEZ, S. Grangemouth ethylene plant installs closed-loop optimization solution. *Oil and Gas Journal*, v. 97, n. 42, p. 83–86, 1999. Citado na página 23.

QU, C. C.; HAHN, J. Computation of arrival cost for moving horizon estimation via unscented kalman filtering. *Journal of Process Control*, v. 19, n. 2, p. 358–363, 2009. ISSN 0959-1524. Citado na página 27.

RAO, C.; RAWLINGS, J. Nonlinear moving horizon state estimation. In: \_\_\_\_\_. [S.l.: s.n.], 2000. v. 26, p. 45–69. ISBN 978-3-0348-9554-5. Citado na página 27.

RODRIGUES, D. et al. Fast estimation of plant steady state for imperfectly known dynamic systems, with application to real-time optimization. *Industrial and Engineering Chemistry Research*, ACS Publications, v. 57, n. 10, p. 3699–3716, 2018. Citado na página 24.

- RODRÍGUEZ-BLANCO, T. et al. Modifier adaptation methodology based on transient and static measurements for rto to cope with structural uncertainty. *Computers and Chemical Engineering*, Elsevier, v. 106, p. 480–500, 2017. Citado na página 25.
- ROUX, G. A. C. L. et al. *Improving steady-state identification*. [S.l.: s.n.], 2008. v. 25. 459-464 p. (Computer Aided Chemical Engineering, v. 25). Cited By :14. Citado na página 29.
- SANTOS, J. E. W.; TRIERWEILER, J. O.; FARENZENA, M. Model update based on transient measurements for model predictive control and hybrid real-time optimization. *Industrial and Engineering Chemistry Research*, ACS Publications, v. 60, n. 7, p. 3056–3065, 2021. Citado na página 25.
- SAWARAGI, Y. et al. Dynamic version of steady state optimizing control of a distillation column by trial method. *Automatica*, Elsevier, v. 7, n. 4, p. 509–516, 1971. Citado na página 23.
- SCHEI, T. S. On-line estimation for process control and optimization applications. *IFAC Proceedings Volumes*, v. 40, n. 5, p. 19–28, 2007. ISSN 1474-6670. 8th IFAC Symposium on Dynamics and Control of Process Systems. Citado 2 vezes nas páginas 27 e 73.
- SCHMIDT GERALD L. SMITH, L. A. M. S. F. Application of statistical filter theory to the optimal estimation of position and velocity on board a circumlunar vehicle. In: . [S.l.: s.n.], 1962. Citado na página 26.
- SEQUEIRA, S. E.; GRAELLS, M.; PUIGJANER, L. Real-time evolution for on-line optimization of continuous processes. *Industrial and Engineering Chemistry Research*, v. 41, n. 7, p. 1815–1825, 2002. Citado na página 23.
- SHAMAKI, P. B.; ODLOAK, D. Hybrid rto with zone control mpc applied to a gas-lift system. In: IEEE. *2020 28th Mediterranean Conference on Control and Automation (MED)*. [S.l.], 2020. p. 691–696. Citado na página 25.
- THOMAS, Y. A. Linear quadratic optimal estimation and control with receding horizon. *Electronics Letters*, v. 11, p. 19–21, 1975. Citado na página 27.
- UNGARALA, S. Computing arrival cost parameters in moving horizon estimation using sampling based filters. *Journal of Process Control*, v. 19, n. 9, p. 1576–1588, 2009. Cited By :37. Citado 2 vezes nas páginas 37 e 38.
- VALLURU, J.; PATWARDHAN, S. C. An integrated frequent rto and adaptive nonlinear mpc scheme based on simultaneous bayesian state and parameter estimation. *Industrial and Engineering Chemistry Research*, ACS Publications, v. 58, n. 18, p. 7561–7578, 2019. Citado na página 25.
-

# Apêndices



# APÊNDICE A – Dados de Validação do Modelo

A [Tabela 4](#) indica as condições testadas na análise de validação do modelo e a [Figura 30](#) contém todas as situações estudadas.

Tabela 4 – Teste de validação

Exp	$v_{pump}$	Vo	$w_{gl}$
1	35%	0.2	[2;4;6;7]
2		0.4	[2;4;6;7]
3		0.6	[2;4;6;7]
4		0.8	[2;4;6;7]
5	50%	0.2	[2;4;6;7]
6		0.4	[2;4;6;7]
7		0.6	[2;4;6;7]
8		0.8	[2;4;6;7]
9	65%	0.2	[2;4;6;7]

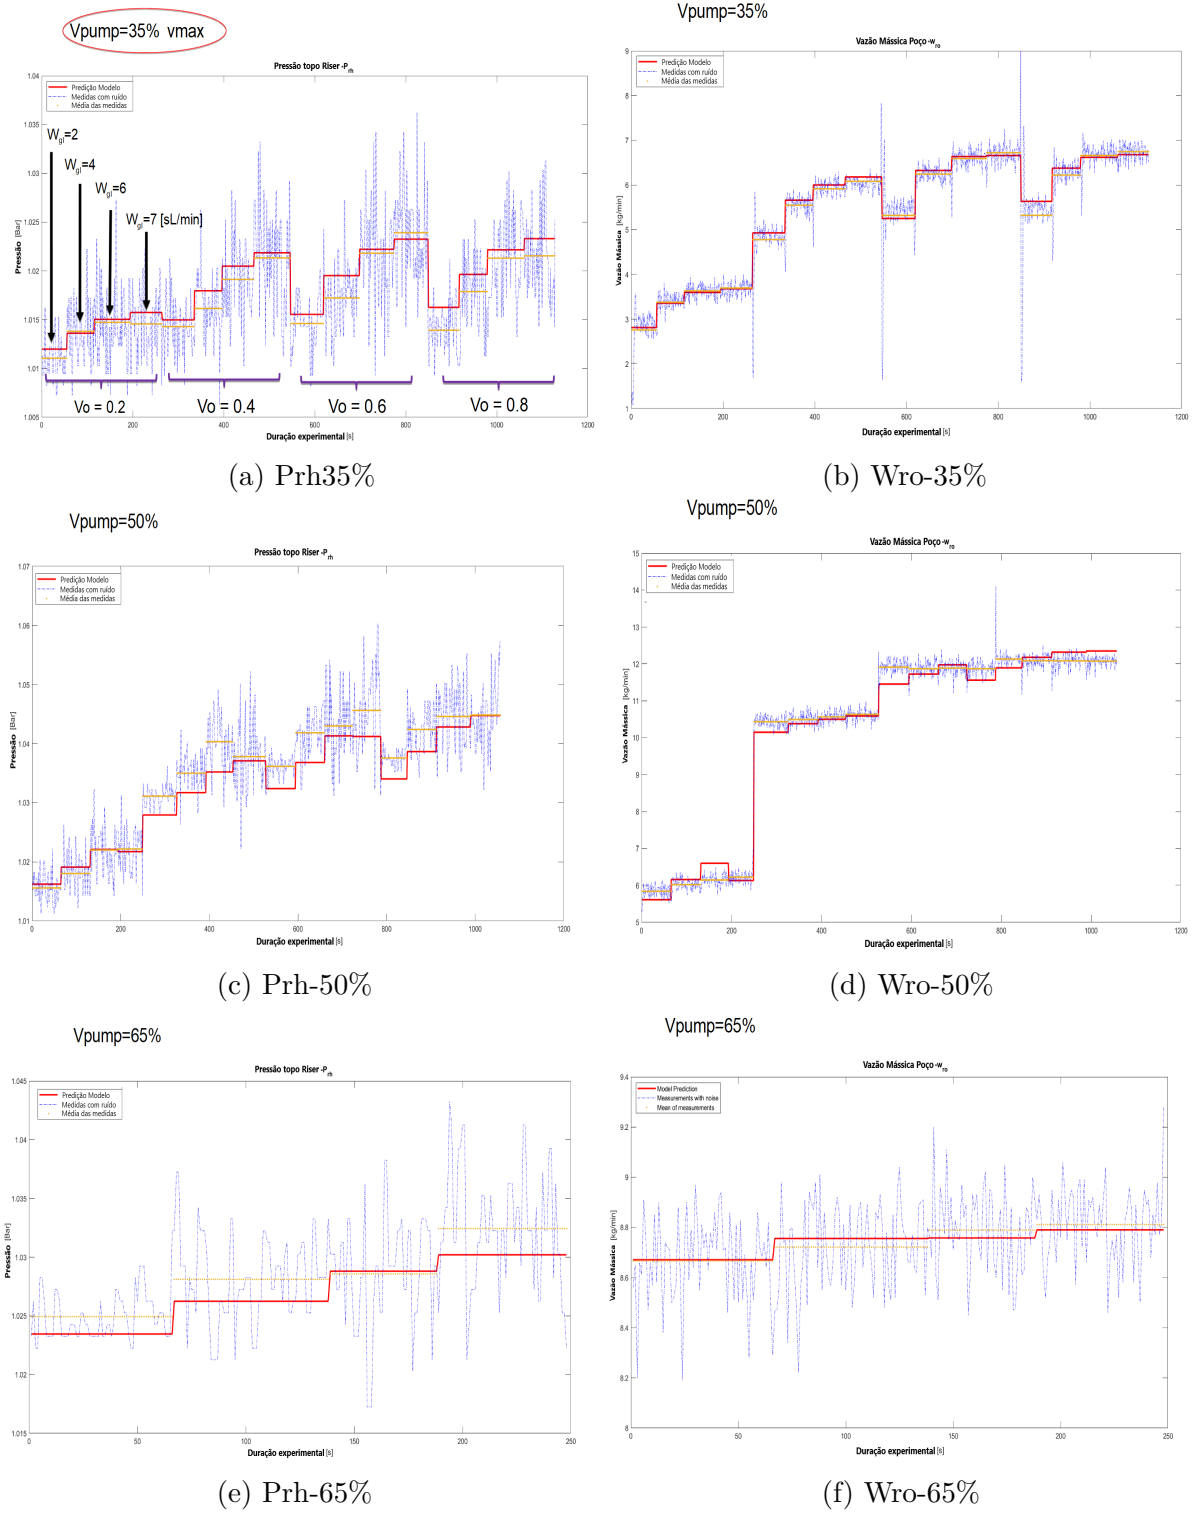


Figura 30 – Dados para validação do modelo.



## APÊNDICE B – Equipamento experimental e descrição do problema da bomba

Como descrito na seção de análise do RTO-MPA um dos poços teve uma vazão menor que a dos outros no mesmo experimento. A [Figura 31](#) mostra o equipamento utilizado nas análises desta dissertação. A imagem mostra os tubos que representam o poço e o riser, a bomba que representa o reservatório e alguns controladores. Na direita há um tanque prateado para o armazenamento de água, uma caixa de passagem elétrica e um *hub* para conectar os diferentes equipamentos à caixa de passagem e ao computador que tem os softwares de controle.




Figura 31 – Foto do equipamento completo utilizado para simulação da operação de *Gas Lift*.

Focando na camada de controle a [Figura 32](#), a válvula prateada com dois medidores libera a passagem de ar. A esquerda da válvula estão os medidores, que são pretos em formato de caixa retangular, da injeção de ar ( $w_{gl}$ ) e associados a eles estão os controladores que fazem a injeção de ar no sistema, indicados pelas etiquetas V-202 e V203. A direita da válvula existem outros medidores que não foram utilizados na nossa análise. Por último, a

etiqueta FI-102 indica o medidor de vazão da bomba e as etiquetas CV-103 e CV-102 os controladores de vazão, que no modelo seriam as aberturas de válvulas *vo*.



Figura 32 – Foto dos controladores.

A [Figura 33](#) mostra a bomba e suas tubulações. A água tem duas direções após sair da bomba, no fluxo convencional a água vai em sentido a etiqueta FI-102, ou seja, vai em direção aos controladores de vazão mostrados na [Figura 32](#). Quando a vazão ou pressão na tubulação for muito alta, a válvula de escape se abre e a água vai no sentido inverso.




Figura 33 – Foto do bomba e suas tubulações.

Considerando o fluxo convencional a água que vem da bomba vai para as três tubulações, entrando primeiro na tubulação mais a esquerda do experimento, FI-101 e CV-101, depois na tubulação do medidor FI-102 e por último na tubulação do medidor FI-103. Como não há garantias de que a vazão será distribuída igualmente, é possível que em alguns experimentos a última tubulação receba menor vazão de água, com isso causando um poço menos produtivo na seção de análise do RTO-MPA.



# APÊNDICE C – Estudo de Caso MHE: Outros cenários estudados

A Figura 34 e Figura 35 são os resultados dos outros cenários estudados no estudo de caso da estimação do MHE

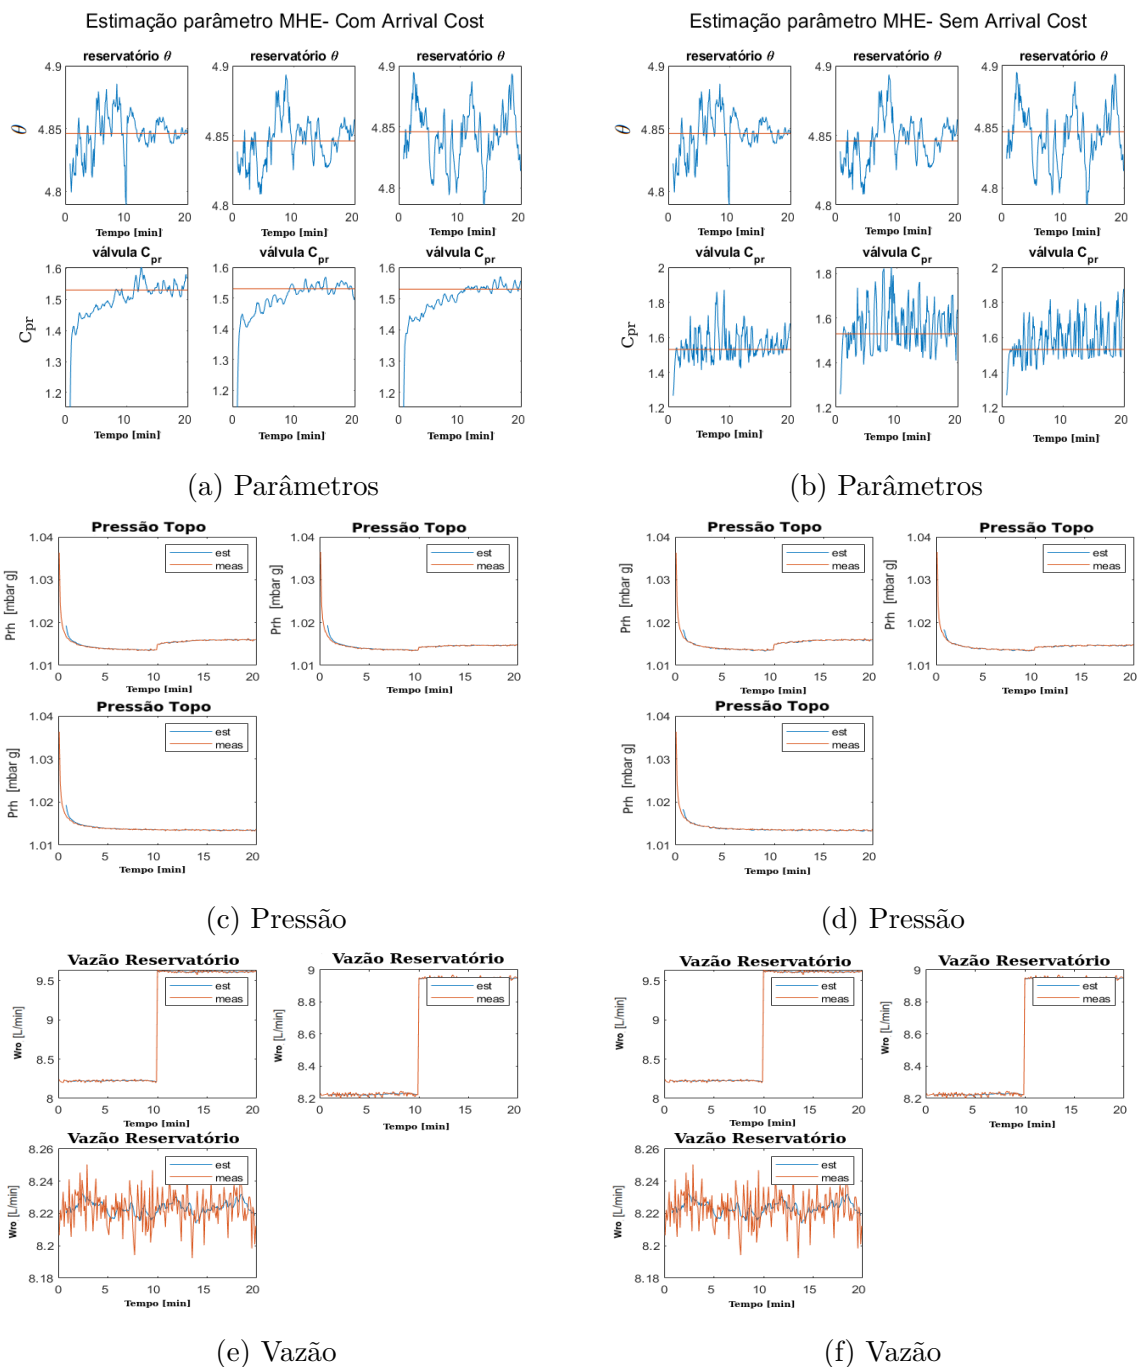


Figura 34 – Estimação MHE para o experimento 2: Parâmetros, Pressão, Vazão.

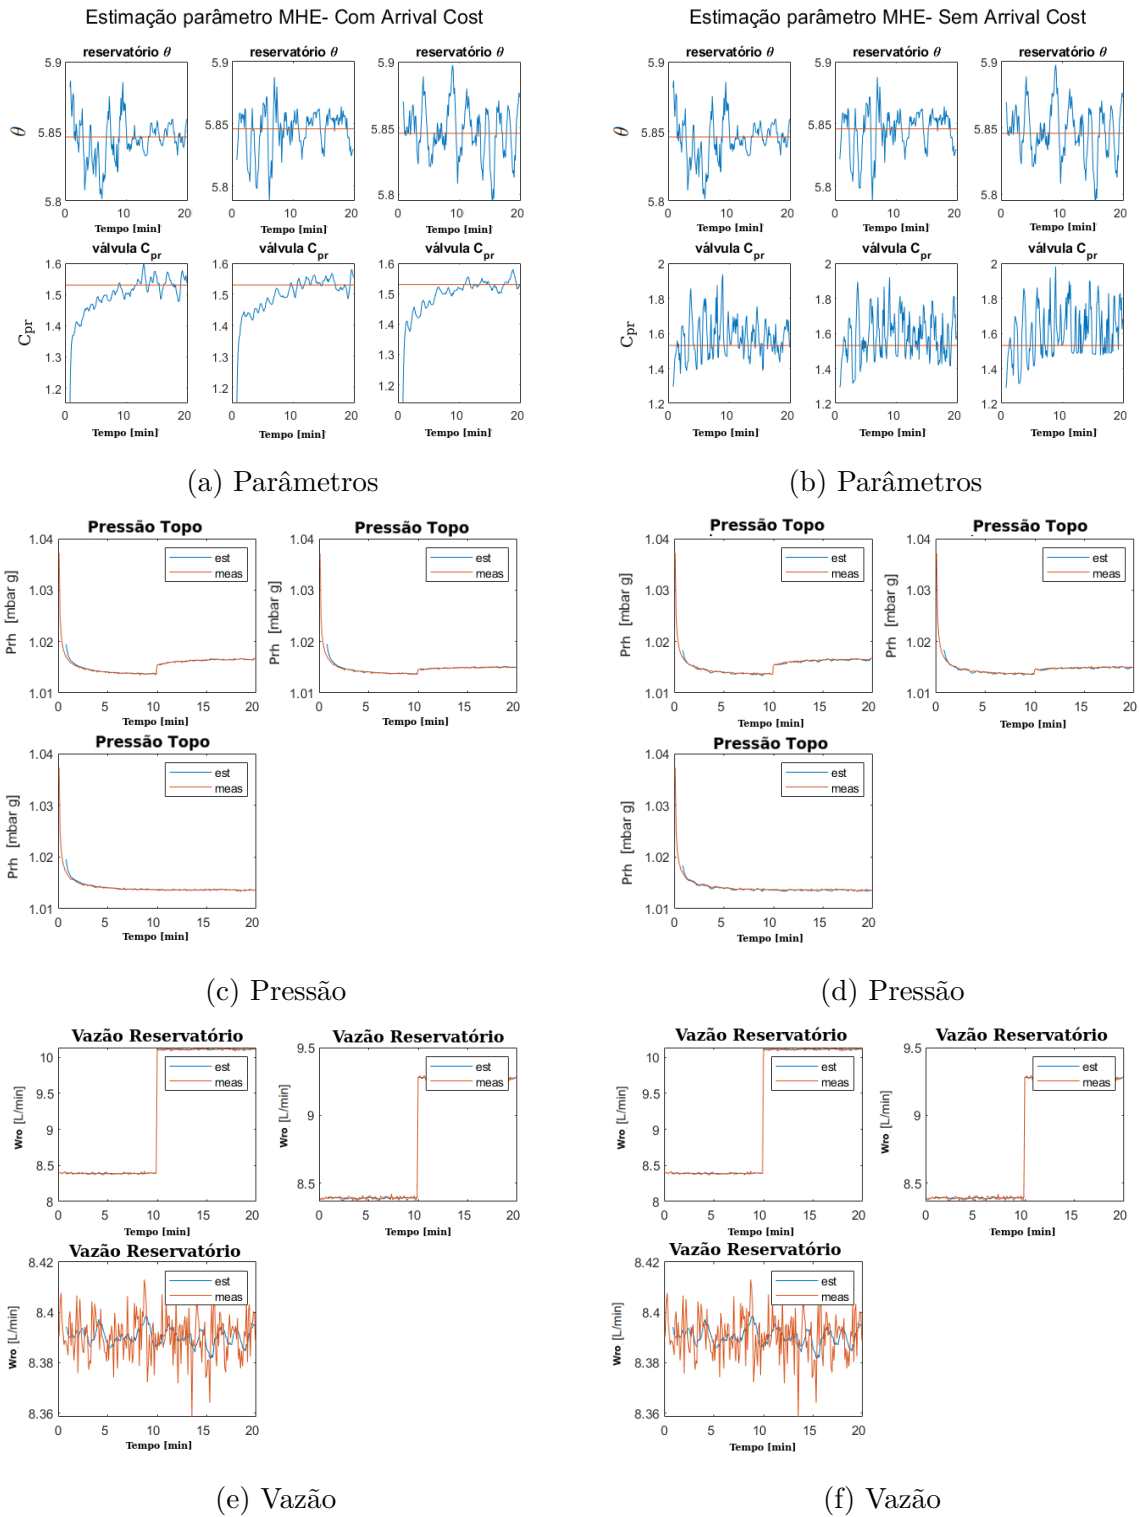


Figura 35 – Estimação MHE para o experimento 3: Parâmetros, Pressão, Vazão.