



**AVALIAÇÃO DA AÇÃO DO FILTRO DE KALMAN
ESTENDIDO NA INFERÊNCIA DE VARIÁVEIS DE TOPO
E FUNDO DE POÇO DE PETRÓLEO**

Mariana Vertuli dos Santos

Projeto Final de Curso

Orientadores

Prof. Argimiro Resende Secchi, D.Sc.

Pedro de Azevedo Delou, M.Sc.

Março de 2022

AVALIAÇÃO DA AÇÃO DO FILTRO DE KALMAN ESTENDIDO NA INFERÊNCIA DE VARIÁVEIS DE TOPO E FUNDO DE POÇO DE PETRÓLEO

Mariana Vertuli dos Santos

Projeto de Final de Curso submetido ao Corpo Docente da Escola de Química, como parte dos requisitos necessários à obtenção do grau de Engenheiro Químico.

Aprovado por:

Eng. Leonardo Dorigo Ribeiro, D.Sc.

Prof. Raquel Massad Cavalcante, D.Sc.

Orientado por:

Prof. Argimiro Resende Secchi, D.Sc.

Pedro de Azevedo Delou, M.Sc.

Rio de Janeiro, RJ - Brasil

Março de 2022

Santos, Mariana Vertuli.

Avaliação da ação do filtro de Kalman estendido na inferência de variáveis de topo e fundo de poço de petróleo / Mariana Vertuli dos Santos. Rio de Janeiro: UFRJ/EQ, 2022.
xi, 81 p.; il.

Projeto Final – Universidade Federal do Rio de Janeiro, Escola de Química, 2022.

Orientadores: Argimiro Resende Secchi e Pedro de Azevedo Delou.

1. Ajuste de medidas. 2. Filtro de Kalman. 3. Extração de petróleo e gás. 4. Projeto Final de Curso (Graduação – UFRJ/EQ). 5. Argimiro Resende Secchi e Pedro de Azevedo Delou I. Avaliação da ação do filtro de Kalman estendido na inferência de variáveis de topo e fundo de poço de petróleo.

Resumo do Projeto Final de Curso apresentado à Escola de Química como parte dos requisitos necessários para obtenção do grau de Engenheiro Químico.

AVALIAÇÃO DA AÇÃO DO FILTRO DE KALMAN ESTENDIDO NA INFERÊNCIA DE VARIÁVEIS DE TOPO E FUNDO DE POÇO DE PETRÓLEO

Mariana Vertuli dos Santos

Março, 2022

Orientadores: Prof. Argimiro Resende Secchi, D.Sc.

Pedro de Azevedo Delou, M.Sc.

Técnicas de estimação de estados têm sido alvo de inúmeros estudos e pesquisas nas últimas décadas e são frequentemente aplicadas no controle preditivo de processos e otimização baseada em modelos matemáticos, oferecendo elevado potencial de melhoramento de produtividade e redução de custos de produção. No caso da produção de petróleo e gás, a instalação e manutenção de sensores físicos se torna dificultada à medida em que são perfurados poços mais profundos e que apresentam condições ambientais mais severas, gerando valor à inferência de variáveis essenciais à operação adequada da planta. Esse trabalho tem como objetivo a inferência de temperaturas e pressões de fundo e topo de um poço de produção de óleo e gás a partir da ação do Filtro de Kalman Estendido. A resolução do modelo matemático, sem a implementação do filtro, apresentou divergências entre as medidas da planta variando até 4,48% e 20,89%, relativos às medidas de temperatura no topo do poço e pressão no fundo do poço, respectivamente; enquanto a aplicação do filtro foi capaz de reduzir estes valores para 0,23% e 0,06% para as mesmas medidas. A avaliação das demais saídas do modelo antes da aplicação do Filtro de Kalman indicou sua aderência mais razoável à inferência de temperaturas do que de pressões. Sendo assim, a aplicação do Filtro de Kalman Estendido em conjunto com a representação do processo pelo modelo matemático utilizado foi capaz de resultar em uma estimação satisfatória das variáveis avaliadas do sistema, apresentando resultados mais significativos para as pressões estudadas.

SUMÁRIO

I. Introdução.....	1
I.1. Importância do tema	1
I.2. Objetivo do trabalho	2
II. Revisão bibliográfica.....	3
II.1. A indústria de produção do petróleo.....	3
II.2. Caracterização do problema da produção	4
II.3. Estimação de estados	6
II.3.1. Filtro de Kalman.....	9
II.3.2. Filtro de Kalman Linearizado.....	12
II.3.3. Filtro de Kalman Estendido.....	12
II.3.4. Filtro de Kalman Estendido com restrições.....	14
II.3.5. Filtro de Kalman <i>Unscented</i>	14
II.4. Modelo de escoamento	15
II.4.1. Escoamento multifásico.....	15
II.4.2. Modelo de Beggs & Brill	18
II.4.3. Especificidades da resolução do modelo.....	20
II.4.4. Implementação do modelo.....	21
III. Metodologia	23
III.1. Abordagem computacional	23
III.2. Aplicação do modelo.....	23
III.3. Análise de sensibilidade	25
III.4. Aplicação do Filtro de Kalman Estendido	26
III.4.1. Estimação dos estados	26
III.4.2. Sintonia das matrizes de covariância	27
IV. Resultados e discussão	30
IV.1. Simulação do modelo	30
IV.2. Análise de sensibilidade	35
IV.3. Aplicação do Filtro de Kalman Estendido	37
V. Conclusões	49
Referências Bibliográficas.....	51
Apêndice I.....	58
Apêndice II.....	66
Apêndice III.....	74

ÍNDICE DE FIGURAS

Figura 1: Esquema simplificado da extração de óleo e gás.	4
Figura 2: Esquema representativo da filtragem de Kalman.	12
Figura 3: Envelope de fases de mistura bifásica de hidrocarbonetos em condições de reservatório. Fonte: Guedes (2015).	16
Figura 4: Esquema representativo da metodologia de implementação do Filtro de Kalman. ...	27
Figura 5: Representação do conjunto de dados fornecidos ao pré-processamento. a: vazão volumétrica de <i>gas lift</i> ; b: pressão do tubo; c: pressão de fundo de poço; d: pressão de topo de poço; e: temperatura de fundo de poço; f: temperatura de topo de poço.	30
Figura 6 : Representação do conjunto de dados fornecidos após o pré-processamento. a: vazão volumétrica de <i>gas lift</i> ; b: pressão do tubo; c: pressão de fundo de poço; d: pressão de topo de poço; e: temperatura de fundo de poço; f: temperatura de topo de poço.	31
Figura 7: Identificação dos intervalos sobre cada uma das medidas. a: vazão volumétrica de <i>gas lift</i> ; b: pressão do tubo; c: pressão de fundo de poço; d: pressão de topo de poço; e: temperatura de fundo de poço; f: temperatura de topo de poço.	33
Figura 8: Comparação entre as medidas da planta e as respostas o modelo. a: variação da pressão no fundo do poço com o tempo; b: variação da pressão de topo de poço com o tempo; c: variação da temperatura de fundo de poço com o tempo; d: variação da temperatura de topo de poço com o tempo.	34
Figura 9: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = I$. a: pressão de fundo de poço; b: pressão de todo de poço; c: temperatura de fundo de poço; d: temperatura de topo de poço.	38
Figura 10: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = I$. a: caso em que $j = 0,01$; b: caso em que $j = 0,05$; c: caso em que $j = 0,1$; d: caso em que $j = 0,5$	39
Figura 11: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = jQ'$. a: pressão de fundo de poço; b: pressão de todo de poço; c: temperatura de fundo de poço; d: temperatura de topo de poço.	42
Figura 12: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = jQ'$. a: caso em que $j = 0,01$; b: caso em que $j = 0,05$; c: caso em que $j = 0,1$; d: caso em que $j = 0,5$	43

Figura 13: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = j\mathbf{Q}'$ e $\mathbf{R} = (1 - j)\mathbf{R}'$. a: caso em que $j = 0,01$; b: caso em que $j = 0,05$; c: caso em que $j = 0,1$; d: caso em que $j = 0,5$	46
Figura 14: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,01\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	58
Figura 15: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,01\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	59
Figura 16: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,01\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	59
Figura 17: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,05\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	60
Figura 18: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,05\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	61
Figura 19: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,05\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	61
Figura 20: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,1\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	62
Figura 21: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,1\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	63
Figura 22: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,1\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$.	63
Figura 23: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = 0,5\mathbf{Q}'$ e $\mathbf{Q}' = \mathbf{I}$	64

Figura 24: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e $Q' = I$	65
Figura 25: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e $Q' = I$. 65	65
Figura 26: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e Q' é igual às variâncias.....	66
Figura 27: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e Q' é igual às variâncias.....	67
Figura 28: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e Q' é igual às variâncias.....	67
Figura 29: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e Q' é igual às variâncias.....	68
Figura 30: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e Q' é igual às variâncias.....	69
Figura 31: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e Q' é igual às variâncias.....	69
Figura 32: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e Q' é igual às variâncias.....	70
Figura 33: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e Q' é igual às variâncias.....	71
Figura 34: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e Q' é igual às variâncias.....	71

Figura 35: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e Q' é igual às variâncias.....	72
Figura 36: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e Q' é igual às variâncias.....	73
Figura 37: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e Q' é igual às variâncias.....	73
Figura 38: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$, Q' é igual às variâncias e $R = 0,99R'$	74
Figura 39: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$, Q' é igual às variâncias e $R = 0,99R'$	75
Figura 40: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$, Q' é igual às variâncias e $R = 0,99R'$	75
Figura 41: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$, Q' é igual às variâncias e $R = 0,95R'$	76
Figura 42: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$, Q' é igual às variâncias e $R = 0,95R'$	77
Figura 43: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$, Q' é igual às variâncias e $R = 0,95R'$	77
Figura 44: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$, Q' é igual às variâncias e $R = 0,9R'$	78
Figura 45: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$, Q' é igual às variâncias e $R = 0,9R'$	79

Figura 46: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$, Q' é igual às variâncias e $R = 0,9R'$	79
Figura 47: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$, Q' é igual às variâncias e $R = 0,5R'$	80
Figura 48: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$, Q' é igual às variâncias e $R = 0,5R'$	81
Figura 49: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$, Q' é igual às variâncias e $R = 0,5R'$	81

ÍNDICE DE TABELAS

Tabela 1: Parâmetros relativos ao poço MML-69.	24
Tabela 2: Variáveis de saída de interesse do modelo desenvolvido por Guedes (2015).	24
Tabela 3: Divisão dos dados em intervalos.	32
Tabela 4: Relação entre os valores de G_L e P_{sep} utilizados na geração das estimativas iniciais e seus valores médios em cada intervalo determinado.	32
Tabela 5: Raiz quadrada do erro quadrático médio, <i>offsets</i> médios, média, desvio padrão, valores máximo e mínimos para P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} simulados.	34
Tabela 6: Resposta de cada uma das variáveis de saída do modelo sobre incrementos individuais de 1% e 10% nos valores de G_L e P_{sep}	36
Tabela 7: Sensibilidade de cada variável de saída do modelo sobre incrementos individuais de 1% e 10% nos valores de G_L e P_{sep}	36
Tabela 8: Raiz quadrada do erro quadrático médio, média, desvio padrão e valores de máximo e mínimo de P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} para cada valor do parâmetro j estudado quando Q é igual à I	40
Tabela 9: Raiz quadrada do erro quadrático médio, média, desvio padrão e valores de máximo e mínimo de P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} para cada valor do parâmetro j estudado quando $Q = jQ'$	44
Tabela 10: Raiz quadrada do erro quadrático médio, média, desvio padrão e valores de máximo e mínimo de P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} para cada valor do parâmetro j estudado quando $Q = jQ'$ e $R = (1 - j)R'$	47

NOMENCLATURA

d	Diâmetro interno da tubulação (m)
f_{tp}	Fator de atrito de Moody
g	Aceleração da gravidade (m/s ²)
G_L	Vazão volumétrica de <i>gas lift</i> (m ³ /h)
H_L	<i>Holdup</i> de líquido
$H_L(0)$	<i>Holdup</i> de líquido em escoamento horizontal
$H_L(\theta)$	<i>Holdup</i> de líquido em escoamento inclinado
I	Matriz identidade
K	Constante de equilíbrio
K_k	Ganho de Kalman no passo k
N_{FT}	Número de Froude
N_{Lv}	Número de velocidade do líquido
P	Pressão (Pa)
P_k	Matriz de covariância dos estados no passo k
P_{PDG}	Pressão no fundo do poço (kgf/cm ²)
P_{sep}	Pressão do tubo à montante (kPa)
P_{TPT}	Pressão no topo do poço (kgf/cm ²)
Q	Matriz de covariância dos ruídos do processo
R	Matriz de covariância dos ruídos da medição
S	Função de Sensibilidade
T_{PDG}	Temperatura no fundo do poço (°C)
T_{TPT}	Temperatura no topo do poço (°C)
u	Vetor de entradas do processo
v	Vetor de ruído da observação
w	Vetor de ruído do processo
x	Vetor de estados do processo
y	Vetor de saídas do processo
β	Fração molar vaporizada
θ	Ângulo de inclinação da tubulação (rad)
λ_L	Fração volumétrica de líquido desconsiderando deslizamento entre fases
v_{SG}	Velocidade superficial do gás (m/s)
v_{SL}	Velocidade superficial do líquido (m/s)
ρ_L	Densidade do líquido (kg/m ³)
ρ_n	Densidade da mistura bifásica ponderada por λ_L (kg/m ³)
ρ_{tp}	Densidade da mistura bifásica ponderada por H_L (kg/m ³)
σ_L	Tensão superficial do líquido (kg/m ³)

I. INTRODUÇÃO

I.1. Importância do tema

A descoberta e exploração de poços de petróleo e gás situados em ambientes cada vez mais hostis e profundos vem tornando as pesquisas acerca das condições de produção cada vez mais relevantes. Diversos fatores contribuem para o caráter desafiador do estudo, principalmente devido ao escoamento multifásico – hidrocarboneto líquido, gás e água – em linhas de produção. Isso porque é possível a existência de diversos regimes de escoamento em linhas de produção, que podem apresentar diferentes velocidades entre as fases que escoam; pode haver a formação de hidratos e precipitação de parafinas a baixas temperaturas; ou até haver erosão interna nas linhas causada por velocidades altas de escoamento. É sob esse contexto que se constrói o termo de “garantia de escoamento”, que tem por definição “o conjunto de estratégias e princípios que garantem a produção de hidrocarbonetos sem interrupção, partindo do reservatório até a entrada do primeiro separador da unidade de produção” (GUEDES, 2015), conceito a partir do qual se embasa a importância do presente trabalho.

Em uma unidade de produção e exploração de óleo e gás natural o fluxo total de produção pode ser monitorado em tempo real, porém os fluxos individuais de gás e de líquido produzidos são usualmente medidos por meio de testes de produção. Esses testes ocorrem muitas vezes em intervalos de tempo razoavelmente espaçados, chegando a cerca de dois meses, não tornando possível a medição da vazão representada por cada fase durante o intervalo entre os testes. Dessa forma, costuma-se ter como pressuposto que no período entre os testes a produção de cada fase é igual à reportada no último teste realizado. Esse tipo de consideração, porém, pode levar a atrasos na detecção de problemas na produção (GÓES *et al.*, 2021), resultando em uma menor produtividade da planta e aumento dos custos operacionais e de manutenção.

Além disso, com o decorrer da operação, é natural que os sensores, como medidores multifásicos, por exemplo, utilizados para monitoração e controle de variáveis indispensáveis durante a exploração de poços de óleo e gás apresentem incertezas nas medidas, que tendem a aumentar com o passar do tempo, dificultando sua utilização devido aos altos custos de manutenção e substituição (GRAHAM, 2015). Configura-se ainda um problema no monitoramento da atividade dos poços a dificuldade de implementação dos sensores físicos devido à inacurácia ou mesmo às condições severas no interior dos poços (LESKENS *et al.*, 2008). Ainda assim, há necessidade de informações acuradas em tempo real de maneira a

garantir uma operação segura e adequada do processo, sendo necessária a estimação ou inferência de tais medidas para aplicação de esquemas de controle.

A utilização de modelos matemáticos capazes de estimar variáveis do sistema a partir de dados referentes às demais variáveis do processo, como uma alternativa aos sensores convencionais, faz-se possível, tornando interessante a utilização do estimador de estados, como um analisador virtual que permite o controle retroalimentado das variáveis do processo e a operação do sistema de controle (FORTUNA *et al.*, 2007; SALAU, 2009).

A partir do modelo desenvolvido por Guedes (2015), aspira-se a avaliação de uma metodologia de estimação de estados visando a predição de variáveis do processo de produção de óleo e gás, tais quais pressão e temperatura no decorrer da linha de produção. O trabalho realizado pela autora teve como objetivo “fornecer as orientações necessárias sobre como proceder em um estudo estacionário típico de garantia de escoamento, apresentando os modelos e correlações mais utilizados, incluindo cálculos de propriedades para pseudocomponentes” (GUEDES, 2015), e mapeou todo o regime de escoamento ao longo da linha de produção. Foi usado o modelo de Beggs & Brill (1973) para cálculo da queda de pressão, que apresentou resultados mais satisfatórios para condições de baixas vazões de produção.

Vale ressaltar que o modelo desenvolvido por Guedes (2015) para o sistema de linhas de produção levou em consideração a modelagem do poço, da porção entre reservatório e cabeça do poço; da *flowline*, que é a porção da linha de produção que liga a cabeça do poço e a base do *riser*; do *riser*, porção responsável pelo deslocamento do fluido do fundo do mar à superfície e; do *topside*, entre o topo do *riser* e a unidade de separação na superfície. As linhas de serviço, tais quais *gas lift*, de injeção de gás, e *dead oil*, responsável pela circulação de “óleo morto”; além das linhas umbilicais, foram excluídas da modelagem realizada. Em seu trabalho foi considerado um poço na fase inicial de operação, para o qual não há produção de água, ou sua produção é desprezível.

I.2. Objetivo do trabalho

Este trabalho possui como objetivo realizar a estimação de pressão e temperatura no topo e fundo de um poço de petróleo e gás natural *offshore*, tomando como base a aplicação do Filtro de Kalman Estendido sobre o modelo matemático desenvolvido por Guedes (2015).

II. REVISÃO BIBLIOGRÁFICA

II.1. A indústria de produção do petróleo

A produção de petróleo e gás natural tem se mostrado de grande relevância para a humanidade nas últimas décadas. O petróleo é a principal fonte de energia na atualidade, além de ser base para a larga cadeia de produtos petroquímicos. Além disso, apesar de diversas fontes de geração energia, renováveis ou não (energia solar, eólica, biocombustíveis, gás de xisto, urânio e outras), terem se mostrado promissoras como substituintes do petróleo nos últimos anos, de acordo com Hassan (2014), óleo e gás natural seguirão dominantes pelas próximas décadas.

O petróleo é um combustível fóssil, originado a partir da decomposição de restos de plantas e animais depositados há milhões de anos na superfície terrestre, que sob ação de altas temperaturas teriam sofrido alterações químicas de suas cadeias carbônicas, de acordo com a teoria orgânica, a mais aceita para descrever a origem dos hidrocarbonetos que compõe o petróleo e gás natural. Diferentemente do óleo, o gás natural pode ser encontrado em depósitos na forma liquefeita ou gasosa, dependendo das condições físicas do ambiente, e é composto principalmente pelo gás metano (BASTIANONI *et al.*, 2005).

A indústria de óleo e gás, na forma que se conhece atualmente, teve seu início no final do século XIX. No início desse século, no noroeste da Pennsylvania, estado localizado nos Estados Unidos da América, produtores realizavam a extração e comercialização do óleo cru a partir da deposição de mantas absorventes em barragens construídas próximas a depósitos de óleo, que flutuava sobre a água (YERGIN, 2008).

Anos depois, Benjamin Silliman, professor da universidade de Yale, identificou a possibilidade de destilação do petróleo em diversas frações de substâncias compostas por carbono e hidrogênio, e averiguou seu uso para a iluminação (YERGIN, 2008). A partir de sua descoberta foi criada a primeira companhia de produção óleo e gás dos Estados Unidos, a Pennsylvania Rock Oil Company.

Em agosto de 1859 foi realizada a primeira extração de petróleo por perfuração, similarmente aos moldes atuais, permitindo a possibilidade de suprimento contínuo de óleo e impulsionando a indústria de óleo e gás (YERGIN, 2008), porém provocando aumento expressivo da oferta de óleo e conseqüente redução drástica nos preços.

O cenário negativo ao desenvolvimento da indústria impulsionou a prática de destilação do óleo, que passou a ser usado para produção de querosene. Após altas e baixas nos preços do mercado de petróleo, a invenção e emprego de motores de combustão interna por

volta dos anos 1870, usados em automóveis e equipamentos de fábricas, reestruturou a indústria de óleo e gás, dando valor aos, até então, subprodutos descartados da destilação (HASSAN, 2014). A partir desse momento, gasolina, gás, diesel, lubrificantes e demais produtos se tornaram comercializáveis e permitiram os avanços da indústria até os dias atuais.

II.2. Caracterização do problema da produção

Um sistema típico de produção de óleo e gás é formado por diversos poços interconectados por uma linha (identificada pelo nome em inglês, *flowline*), responsável pelo deslocamento dos fluidos desde a cabeça do poço (*wellhead*) até um segmento identificado como *riser*, linha que realiza a conexão entre a *flowline* e um separador.

O sistema de separação tem como função a divisão do fluido – em geral multifásico, contendo óleo, gás, água e demais resíduos, como areia e asfaltenos (FALCONE *et al.*, 2009) – em gás, óleo e água, permitindo o processamento das frações. No caso de sistemas não submersos, a conexão entre a *flowline* e o separador é direta. A Figura 1 ilustra o sistema descrito.

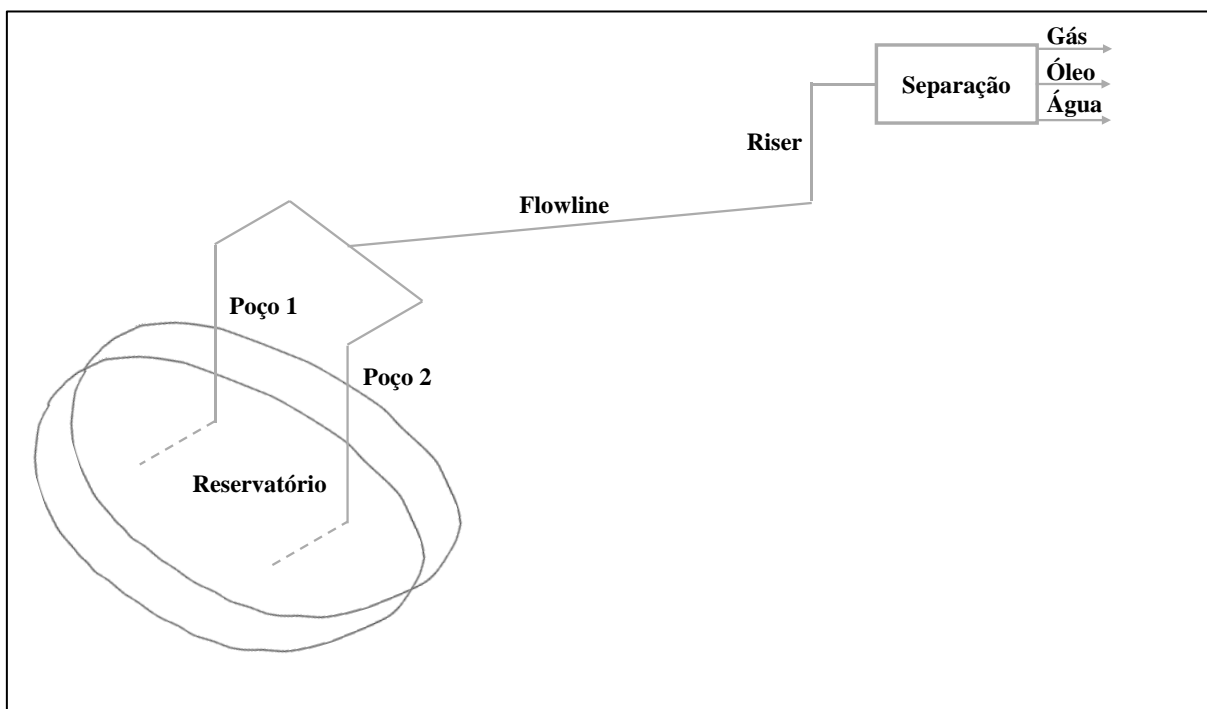


Figura 1: Esquema simplificado da extração de óleo e gás.

O fluxo de óleo e gás que deixa o poço é controlado por válvulas instaladas na cabeça do poço. O monitoramento desses fluxos permite que decisões críticas sejam realizadas em função da otimização da produção, alocação de fluxo, gerenciamento do reservatório e previsão

do desempenho futuro do campo (BIKMUKHAMETOV & JÄSCHKE, 2020), permitindo a gestão econômica mais eficiente.

A testagem direta foi o primeiro e principal método para estimação dos fluxos dos poços no início da atividade industrial de óleo e gás. A partir do deslocamento de uma corrente vinda do poço para o interior de um separador destinado à testagem, o conteúdo era dividido em óleo, gás e água e os fluxos individuais eram medidos na saída do separador (CORNELIUSSEN *et al.*, 2005). Para que essa abordagem seja realizada sem que o processo de extração seja paralisado, é necessária a instalação de uma *flowline* auxiliar. Ainda, seria possível a medição do fluxo individual de cada poço por duas alternativas: parar todos os poços, com exceção daquele em que se deseja determinar o fluxo – alternativa economicamente inviável devido às grandes perdas na produção – ou parar a atividade apenas do poço em que se deseja determinar o fluxo e calcular seu valor a partir da subtração do fluxo antes e após a parada, método chamado de “*deduction well testing*” (teste de poço por dedução, em tradução livre) (IDSØ *et al.*, 2014). Em todos os casos, o desempenho dos demais poços será afetado pelo desligamento de um, causando erros na determinação dos fluxos; além de ser possível que se levem horas até que condições estáveis de fluxo sejam alcançadas e permitam a realização dos testes, dependendo da distância entre o poço e o separador (FALCONE *et al.*, 2001; IDSØ *et al.*, 2014).

Além disso, conforme previamente mencionado, sensores físicos utilizados para monitoramento e controle ao longo da linha de produção tendem a apresentar incertezas crescentes com o decorrer da operação, tendo seu uso dificultado pelos custos altos de manutenção e substituição (GRAHAM, 2015), ou mesmo pelas condições extremas no ambiente (LESKENS *et al.*, 2008).

No início dos anos 1990, por exemplo, iniciou-se a comercialização de medidores multifásicos de vazão como uma alternativa ao procedimento de testes (FALCONE *et al.*, 2001), que realizam a estimação dos fluxos sem a necessidade de separação prévia das fases com base em medidas auxiliares de algumas propriedades do fluido, como velocidade e frações no interior do equipamento (GRYZLOV, 2011). Esses medidores são, em geral, instalados na cabeça do poço, permitindo a determinação das vazões das fases de cada poço em tempo real (IDSØ *et al.*, 2014).

Nos últimos anos, diversas tecnologias foram desenvolvidas para promover uma maior acurácia aos medidores multifásicos, porém, assim como a estratégia de testagem de poços, o uso de tais medidores apresenta vantagens e desvantagens. O principal interesse acerca de sua

utilização é devido à sua capacidade de promover as informações desejadas em tempo real, porém esses medidores possuem um alto custo de instalação e manutenção e necessitam de intervenção em caso de falhas (FALCONE *et al.*, 2001; PATEL *et al.*, 2014). Além disso, esses medidores possuem um intervalo de operação específico, a partir do qual a acurácia das medidas tende a decair; e podem sofrer degradação ou bloqueio parcial com o passar dos anos devido à erosão pelas condições do ambiente onde são instalados, causando despesas econômicas e redução da acurácia (MARSHALL & THOMAS, 2015).

Ainda assim há necessidade de informações em tempo real para garantia de operação adequada do processo, e nesse sentido, surge a estratégia de medição virtual (do inglês, *Virtual Flow Metering*, VFM), baseada na determinação das variáveis a partir da alimentação em modelos numéricos com dados coletados em campo (TOSKEY, 2012). Tal abordagem não necessita da instalação de dispositivos de medição adicionais, reduzindo os custos operacional e de capital; além de gerarem estimativas em tempo real e serem capazes de mapear mudanças nas condições operacionais dos fluxos (MARSHALL & THOMAS, 2015). A estratégia pode ser usada como uma solução isolada ou em combinação com sistemas de medidores de vazão multifásicos, servindo como um método de *back-up* em caso de falhas e redundância de informação (HOLMÅS *et al.*, 2013).

II.3. Estimação de estados

A representação de um sistema em modelo de espaço de estados é uma maneira compacta e prática de descrever as relações entre suas variáveis internas. Para sistemas lineares, o modelo matemático é dado de acordo com as equações apresentadas a seguir, nas quais \mathbf{x} representa o vetor de estados, \mathbf{u} o vetor de entradas, \mathbf{y} o vetor de saídas de um determinado sistema dinâmico, \mathbf{A} , \mathbf{B} e \mathbf{C} as matrizes dos coeficientes do modelo em tempo contínuo, e \mathbf{F} , \mathbf{G} e \mathbf{H} as matrizes dos coeficientes do modelo em tempo discreto. A Equação 2-1 descreve sistemas lineares contínuos e a Equação 2-2 descreve sistemas lineares discretos.

$$\begin{aligned}\dot{\mathbf{x}} &= \mathbf{Ax} + \mathbf{Bu} \\ \mathbf{y} &= \mathbf{Cx}\end{aligned}\tag{2-1}$$

$$\begin{aligned}\mathbf{x}(k+1) &= \mathbf{Fx}(k) + \mathbf{Gu}(k) \\ \mathbf{y}(k) &= \mathbf{Hx}(k)\end{aligned}\tag{2-2}$$

O objetivo do estimador de estados é combinar medições disponíveis em um dado sistema com um modelo matemático capaz de descrevê-lo satisfatoriamente, de maneira a estimar o vetor de estados e fornecer as informações necessárias para o controle eficiente e avançado do processo (CAPRON, 2021). Isso é necessário pois, em diversos problemas reais,

não é possível que se obtenham dados referentes a todas as variáveis do processo apenas por medições. O controle preditivo e a otimização com base em modelos matemáticos são exemplos de aplicações frequentemente apoiadas em técnicas de estimação de estados, de acordo com Backx *et al.* (1998), sendo cruciais para um alto desempenho operacional da planta.

Existem diversas técnicas de estimação de parâmetros, que dependem diretamente da acurácia do modelo matemático que descreve processo em questão para que os resultados obtidos sejam satisfatórios (WANG *et al.*, 2018). A acurácia dos resultados preditos é aumentada quando é possível a inclusão de parâmetros referentes às incertezas e restrições do sistema (RAO, 2002).

O desempenho do estimador de estados pode ser afetado pelas três fontes de informação que conduzem à implementação do mesmo, são estas: as variáveis medidas, o modelo do processo e as estatísticas de ruído (SALAU, 2009).

Em relação às variáveis medidas, deve-se atentar à existência de erros aleatórios ou grosseiros. Os primeiros são medidas que desrespeitam às leis de conservação de massa e energia, inerentes ao processo, identificados usualmente como ruídos. Os erros grosseiros não seguem a distribuição estatística de dados e podem ser divididos como desvios sistemáticos ou discrepantes. No primeiro caso, os erros são atribuídos à erros de instalação ou calibração de equipamentos de medição, gerando valores intermediários e não discrepantes das medidas; já no segundo caso, os erros são atribuídos a falhas temporárias em elementos do sistema de medição, gerando medidas com desvios anormais (BAGAJEWICZ & JIANG, 1998).

Um modelo adequado de processo para estimadores de estados deve ser robusto, bem representativo e detalhado, o que demanda grande custo desde sua formulação até sua implementação em práticas industriais, em especial para casos de modelos dinâmicos e não lineares. Erros na etapa de linearização de tais modelos, requerida por diversas abordagens de estimação de estados, podem levar a incompatibilidades entre os valores estimados e os reais (WANG *et al.*, 2018).

As estatísticas do ruído, de acordo Valappil & Georgakis (2000), se dão por conta da impossibilidade de reprodução do instrumento utilizado na medida; porém, em problemas reais, tais estatísticas são usualmente desconhecidas e não obedecem a considerações de distribuição normal. Nesse caso, configuram-se fontes de discrepância entre as medidas reais e as medidas estimadas.

Sensores virtuais podem ser integrados à infraestrutura existente em uma planta e, a partir de dados de demais variáveis de um processo, permitir a modelagem e otimização da

produção em tempo real. Por isso, técnicas de estimação de estados com base em sensores virtuais têm sido amplamente estudadas e são fundamentadas em três métodos descritos por Fortuna *et al.* (2007): a modelagem física do processo, a estatística multivariada e a modelagem de inteligência artificial (redes neurais, lógica *fuzzy* e métodos híbridos).

García *et al.* (2010), com base em dados de sensores, testes e simulações, apresentaram uma estratégia de estimação da produção individual de poço com base em redes neurais e lógica de correlação *on-line* com erros inferiores a 4%. Agu & Lie (2014) conduziram um estudo que indicou que o fluxo de um fluido em um canal retangular pode ser medido com precisão em condições de estado estacionário e pode ser determinado por ação do Filtro de Kalman aplicado sobre modelo matemático baseado nas equações de Saint-Venant. Al-Qutami *et al.* (2017) propuseram um sensor virtual baseado em redes neurais para estimação de taxas de fluxos em linhas de óleo e gás, atuando como uma alternativa de *backup* no caso de falhas nos sensores de fluxo multifásicos. Ursini *et al.* (2019) desenvolveu um sensor virtual em tempo real para medida de fluxo capaz de compilar informações da rede de produção e de reservatório a partir da integração entre softwares comerciais e algoritmos de otimização. O sensor desenvolvido foi aplicado em um campo de produção de gás natural offshore e realizou previsões confiáveis a partir de dados de temperatura e pressão.

Os estimadores com base no Filtro de Kalman são amplamente utilizados devido à sua simplicidade e efetividade (SALAU, 2009), com aplicações em diferentes campos de estudo, que se estendem desde a indústria química e petroquímica, passando por áreas de cálculos espaciais, navegação inercial, sistemas de posicionamento (GPS), cálculo de órbitas de espaçonaves, até a inteligência artificial, como em sistemas de reconhecimento de imagem (LI *et al.*, 2016). Entretanto, abordagens baseadas nas filtragens de Kalman podem apresentar resultados imprecisos, sobretudo em cenários que envolvem a avaliação de sistemas não lineares, por levar em consideração modelos linearizados do sistema original, ou com restrições físicas (RAWLINGS & BAKSHI, 2006), que se configuram as principais limitações da utilização do Filtro de Kalman.

Visando uma melhor adequação do estimador e maior acurácia, são reportadas na literatura diversas adaptações que permitem sua aplicação em sistemas específicos ou mesmo fazem a incorporação de restrições físicas. De acordo com Salau (2009), os estimadores de estados desenvolvidos com base na filtragem de Kalman, desde que projetados adequadamente, promovem uma relação satisfatória entre custo computacional e desempenho. Ainda assim, o estudo de demais estimadores, que apresentam maior robustez e precisão de resultados, como

os Estimadores de Horizonte Móvel (MHE), é defendido por diversos autores, principalmente devido à presença das restrições físicas em sua formulação original (HASELTINE, & RAWLINGS, 2005; RAO *et al.*, 2003).

Tonel *et al.* (2008) avaliaram os estimadores baseados no Filtro de Kalman, Filtro de Kalman Estendido (EKF, do inglês, *Extended Kalman Filter*) e Filtro de Kalman Estendido com Restrições (CEKF, do inglês, *Constrained Extended Kalman Filter*), e Estimação de Horizonte Móvel (MHE, do inglês, *Moving Horizon Estimation*) para casos típicos de problemas de controle envolvendo modelos aproximados, não lineares, com inversão do sinal do ganho, estimativas iniciais inseguras e com perturbações. Apesar dos resultados obtidos a partir de MHE apresentarem maior acurácia, acompanhado por maior esforço computacional, os estimadores baseados no Filtro de Kalman apresentaram bons resultados mesmo para problemas com inversão do sinal do ganho e sob menor custo computacional.

Além das técnicas descritas, diversas outras vêm sendo estudadas nos últimos anos, tais quais o Filtro de Partículas, o Filtro de Kalman de Cubatura (CKF, do inglês, *Cubature Kalman Filter*) e o Filtro de Kalman *Unscented* (UKF, do inglês, *Unscented Kalman Filter*) (LI *et al.*, 2016; SANTOS-LEÓN *et al.*, 2021; JULIER & UHLMANN, 1997). Mahfouz *et al.* (2014) propuseram um método que combina técnicas de aprendizado de máquina com Filtro de Kalman para estimação de aceleração e posição instantâneas. Bai *et al.* (2020) desenvolveram uma versão do Filtro de Kalman baseada em redes neurais, eficiente na filtragem de ruídos para alimentação de medidas em terminais inteligentes.

No decorrer da Seção II.3.1 são brevemente comentadas algumas variações comumente aplicadas do Filtro de Kalman (KF, do inglês, *Kalman Filter*). Maior detalhamento e formulação matemática são desenvolvidos para os métodos KF convencional e EKF, sendo esse último aquele aplicado na execução deste trabalho.

II.3.1. Filtro de Kalman

O Filtro de Kalman é um algoritmo proposto em 1960 por R. E. Kalman capaz de estimar variáveis desconhecidas com relativa acurácia a partir de uma série de dados observados em um intervalo de tempo contendo ruídos (LI *et al.*, 2016) e demais fatores de erro em sistemas dinâmicos lineares, conforme mencionados na Seção II.3.

O Filtro de Kalman se mostra um excelente estimador de estados em sistemas lineares, sem restrições e com ruídos de medidas que possam ter distribuição Gaussiana (SALAU, 2009). Para aqueles sistemas que não exibem comportamentos e um modelo descritivo conforme os

ideais para aplicação do filtro convencional, como uma modelagem não linear, por exemplo, dispõem-se de demais abordagens com base no modelo de Kalman, visto que este não pode ser diretamente aplicado (HASELTINE & RAWLINGS, 2005).

Na aplicação do Filtro de Kalman discreto, o estado do sistema é representado na forma de um vetor de números reais, e que a cada intervalo de tempo k avaliado, é aplicado um operador linear sobre o estado, o que resulta na predição do próximo estado. Um segundo operador linear a ser aplicado gera as observações do estado real.

O modelo matemático que descreve o sistema deve ser ajustado conforme os parâmetros do Filtro de Kalman, especificando-se as matrizes do modelo de transição de estados, \mathbf{F}_k , do modelo de observação, \mathbf{H}_k , da covariância do ruído do processo, \mathbf{Q} , da covariância do ruído da observação, \mathbf{R} e, se existente, do modelo das entradas de controle, \mathbf{G}_k .

A Equação 2-3 descreve o modelo de obtenção do estado real em dado tempo k , a partir do estado em tempo anterior $k - 1$, com base no modelo de transição de estados aplicado ao estado anterior \mathbf{x}_{k-1} , no modelo das entradas aplicado no vetor de entradas \mathbf{u}_{k-1} e no ruído do processo \mathbf{w}_{k-1} , para o qual assume-se que segue distribuição normal multivariada de média zero e covariância \mathbf{Q} .

$$\mathbf{x}_k = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{G}_k \mathbf{u}_{k-1} + \mathbf{w}_{k-1} \quad (2-3)$$

A equação de observação se dá de acordo com a Equação 2-4, a partir da aplicação do modelo de observação (\mathbf{H}_k) sobre o estado real, acrescida do ruído da observação, \mathbf{v}_k , branco, de média zero e covariância \mathbf{R} .

$$\mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (2-4)$$

O filtro de Kalman é dividido em duas fases: de predição e de atualização, ou correção. Na primeira fase, a estimativa do estado no passo temporal anterior é utilizada para o cálculo da estimativa do estado no tempo atual, chamada de estimativa *a priori*. Na fase seguinte, combina-se a estimativa obtida *a priori* com a observação das medidas atuais para refinamento da estimativa do estado, chamada de estimativa *a posteriori*.

A fase de predição é governada pelas equações que seguem, em que $\hat{\mathbf{x}}_{k|k-1}$ representa a estimativa de \mathbf{x} no tempo k dadas as observações no tempo $k - 1$ e $\mathbf{P}_{k|k-1}$ representa a matriz de covariância do erro *a priori*:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{G}_k \mathbf{u}_{k-1} \quad (2-5)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Q} \quad (2-6)$$

Na etapa de atualização é calculado o valor do Ganho e Kalman (\mathbf{K}_k), e as seguintes equações são aplicadas:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \tilde{\mathbf{y}}_k \quad (2-7)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (2-8)$$

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (2-9)$$

Nas quais, \mathbf{S}_k corresponde ao resíduo da covariância, $\tilde{\mathbf{y}}_k$ ao resíduo da medição, \mathbf{I} à matriz identidade, \mathbf{H}_k^T à transposta da matriz de observação no passo de tempo k e \mathbf{z}_k , na Equação 2-11, à medida no passo de tempo k . O resíduo da covariância e da medição são dados pelas equações:

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R} \quad (2-10)$$

$$\tilde{\mathbf{y}}_k = \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1} \quad (2-11)$$

O valor esperado (E) das estimativas *a posteriori* em relação às condições iniciais do problema, do resíduo de medição e das matrizes de covariância devem satisfazer as relações das Equações 2-12 a 2-16:

$$E[\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}] = E[\mathbf{x}_k - \hat{\mathbf{x}}_{k|k-1}] = 0 \quad (2-12)$$

$$E[\tilde{\mathbf{y}}_k] = 0 \quad (2-13)$$

$$\mathbf{P}_{k|k} = \text{cov}(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}) \quad (2-14)$$

$$\mathbf{P}_{k|k-1} = \text{cov}(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k-1}) \quad (2-15)$$

$$\mathbf{S}_k = \text{cov}(\tilde{\mathbf{y}}_k) \quad (2-16)$$

Na Figura 2 é exibida uma representação visual da aplicação do Filtro de Kalman sobre um sistema de malha de controle simples. Nesse cenário, a porção superior representa a malha de controle, na qual \mathbf{F}_k é a matriz de estados do sistema, \mathbf{G}_k a matriz das entradas do sistema, \mathbf{x} o vetor de estados, \mathbf{z} o vetor de saída, \mathbf{w}_k o ruído do processo, \mathbf{v}_k o ruído na medida do sinal e \mathbf{T} o operador de atraso de uma amostragem. Já a porção inferior da representação remete à aplicação do modelo do Filtro de Kalman sobre o sistema, no qual $\hat{\mathbf{z}}_k$ a estimativa do sinal de saída do sistema e \mathbf{K}_k o Ganho de Kalman.

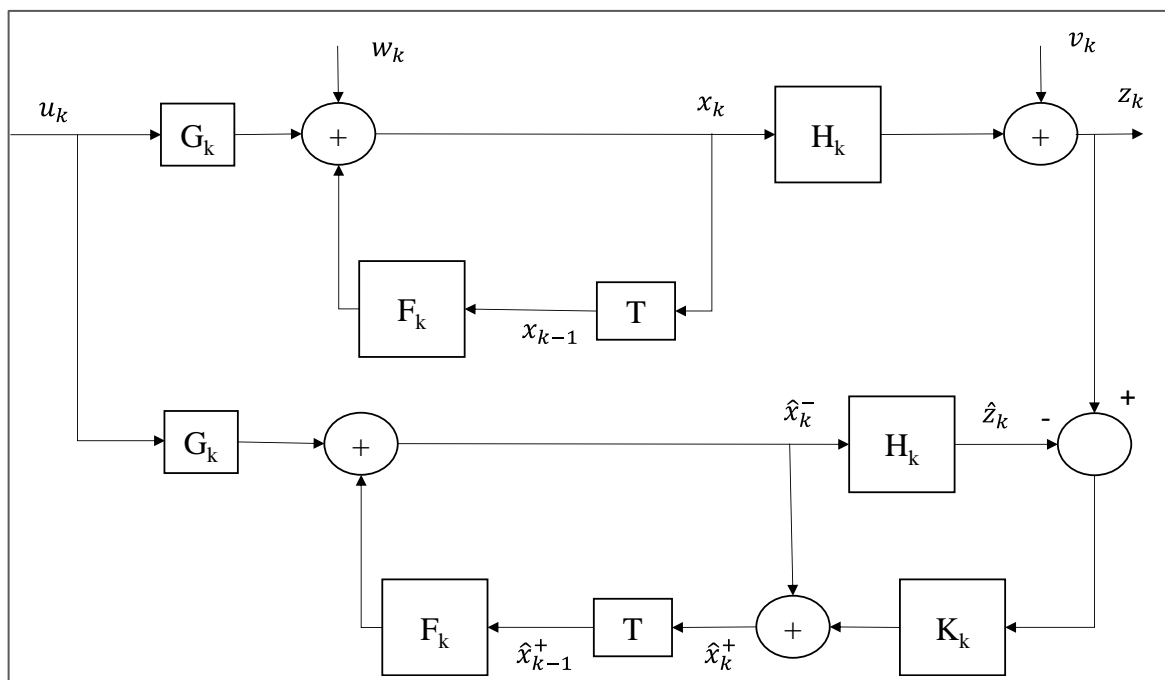


Figura 2: Esquema representativo da filtragem de Kalman.

II.3.2. Filtro de Kalman Linearizado

O Filtro de Kalman Linearizado (LKF, do inglês, *Linearized Kalman Filter*) é uma maneira de se aplicar o filtro sobre um modelo matemático não linear do processo ou medidas não lineares.

Para sua aplicação as dinâmicas do processo ou a relação entre as medidas devem ser linearizadas sobre uma trajetória de referência no espaço de estado que não depende das medidas (BROWN & HWANG, 1997). Em seu emprego consideram-se tanto o ruído de processo quanto o erro de medida processos aleatórios, gaussianos e com média zero.

O LKF apresenta como estado estimado a estimativa da diferença entre os estados real e o de referência, definido com base na trajetória de referência na ausência de ruído. Analogamente, a medida no modelo linear será dada com base na diferença entre as medidas real e a estimada.

II.3.3. Filtro de Kalman Estendido

O EKF se caracteriza por ser um método de estimação não linear de simples aplicação (LI *et al.*, 2016), porém possui determinadas restrições ao uso reportadas em literatura. Dentre essas, destaca-se que seus resultados se aproximam aos valores reais apenas quando as equações de observação e estado do sistema não possuem alto grau de não linearidade (SANTOSH, 2015).

O EKF emprega a linearização de um modelo não linear por expansão em séries de Taylor de primeira ordem. A versão para o EKF com base em expansão em séries de Taylor de segunda ordem existe, porém devido à sua complexidade, seu uso torna-se dificultado na prática, principalmente para análises em tempo real (LEWIS *et al.*, 2006). Um desafio do uso do EKF se dá devido à necessidade de boas estimativas iniciais, que podem levar a um sistema divergente em caso de erros (JULIER *et al.*, 1995).

Lopes & Peixoto (2020) obtiveram convergência e baixo esforço computacional na aplicação do EKF na estimativa de velocidade e posição do rotor, para aplicação em sistema de controle de velocidade *sensorless* para motores de indução trifásicos. O EKF também apresentou bons resultados lidando com sistemas não lineares simples, além de rápida convergência, para a estimativa e controle de órbitas de naves espaciais nos testes conduzidos por Habib (2013).

Tomando como base o KF, o EKF é um observador estocástico que, a partir de sinais ruidosos, realiza a estimação de variáveis em sistemas não lineares (LOPES & PEIXOTO, 2020).

A função \mathbf{f} , apresentada na Equação 2-17 representa sistemas não lineares discretos, descritos conforme segue:

$$\mathbf{x}_k = \mathbf{f}[\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{w}_{k-1}] \quad (2-17)$$

$$\mathbf{z}_k = \mathbf{h}[\mathbf{x}_k, \mathbf{v}_k] \quad (2-18)$$

A cada passo de tempo os valores dos ruídos \mathbf{w}_{k-1} e \mathbf{v}_k são desconhecidos. Esses valores são considerados nulos e os vetores de estado e medidas são aproximados, resultando nas seguintes relações:

$$\mathbf{x}_k = \mathbf{f}[\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{0}] \quad (2-19)$$

$$\mathbf{z}_k = \mathbf{h}[\mathbf{x}_k, \mathbf{0}] \quad (2-20)$$

A linearização do sistema não-linear resulta nas Equações 2-21 a 2-23, nas quais \mathbf{F}_k representa a matriz jacobiana de \mathbf{f} com relação aos estados, \mathbf{H}_k a matriz jacobiana de \mathbf{h} com relação aos estados e \mathbf{G}_k a matriz jacobiana de \mathbf{f} com relações às entradas do processo:

$$\mathbf{F}_k = \left(\frac{\partial \mathbf{f}}{\partial \mathbf{x}} \right)_{\hat{\mathbf{x}}_{k|k-1}} \quad (2-21)$$

$$\mathbf{H}_k = \left(\frac{\partial \mathbf{h}}{\partial \mathbf{x}} \right)_{\hat{\mathbf{x}}_{k|k-1}} \quad (2-22)$$

$$\mathbf{G}_k = \left(\frac{\partial \mathbf{f}}{\partial \mathbf{u}} \right)_{\mathbf{u}_{k|k-1}} \quad (2-23)$$

De maneira análoga ao KF, as etapas de predição e atualização são descritas conforme apresentado nas Equações 2-5 a 2-9.

II.3.4. Filtro de Kalman Estendido com restrições

O CEKF é uma abordagem proposta por Gesthuisen *et al.* (2001) para resolução de problemas de otimização dinâmica não linear, cuja concepção se dá de maneira semelhante ao problema de otimização do MHE, outra metodologia de estimação de estados, que demanda maior esforço computacional. No caso do CEKF, porém, parte-se da consideração de que o comprimento do horizonte é nulo, o que permite que as equações diferenciais ordinárias, que exigem alto esforço computacional para sua resolução, não sejam consideradas no problema. Como consequência, a resolução do problema tem sua complexidade reduzida em comparação do MHE e, juntamente, o esforço computacional.

Apesar de tanto no caso do EKF quanto no caso do CEKF a estimação do estado atual ser realizada apenas com base na medida atual no horizonte de estimação, a principal diferença entre as abordagens é que durante a formulação do CEKF as restrições físicas do sistema são incorporadas às variáveis de estado, tornando possível a avaliação mais acurada de problemas com restrições.

Na ausência de qualquer restrição e para incertezas pequenas no ruído de processo, ambos os estimadores fornecem o mesmo resultado.

Dentre as vantagens dessa técnica, destaca-se a possibilidade da exploração das restrições de estados em um sistema ao mesmo tempo que a demanda por custo computacional é relativamente baixa em comparação ao MHE, tornando seu uso na prática mais plausível. Ao mesmo tempo, a técnica é considerada próxima ao EKF por trabalhar com medidas em um único instante de tempo, ao invés de uma trajetória de medidas, como o MHF.

II.3.5. Filtro de Kalman *Unscented*

A abordagem o UKF é utilizada como alternativa para estimação de estados de modelos não lineares. Seu cálculo é semelhante ao algoritmo utilizado no EKF, porém a partir da utilização de estratégias de amostragens, como amostragem Gaussiana ou de medidas de assimetria (*Skewness sampling strategy*), apresenta desempenho superior e evita divergências reportadas com o EKF (LI *et al.*, 2016).

O algoritmo trabalha a partir da aproximação da distribuição de densidade de probabilidade de funções não lineares ao invés da linearização da função não linear para

estimação de estados. Os resultados obtidos a partir do UFK apresentam, em geral, boa acurácia e convergência mais acelerada do que a abordagem do EKF, porém sua implementação requer maior complexidade e custo computacional (AHRENS *et al.*, 2013; HONG-DE *et al.* 2012; YANG & LI, 2012; SÄRKKÄ, 2009).

II.4. Modelo de escoamento

Conforme explicitado na Seção I.1 será utilizado modelo matemático de escoamento desenvolvido por Guedes (2015) para aplicação do Filtro de Kalman Estendido (EKF). Durante seu trabalho, Guedes (2015) avaliou a acurácia do modelo para três casos distintos, são estes:

- i) Fluido escoando na máxima vazão permitida (15 kg/s) e *flowline* sem isolamento, permitindo a determinação de seu diâmetro interno;
- ii) Fluido escoando na mínima vazão permitida (5 kg/s) e *flowline* com isolamento, permitindo a determinação da menor espessura de isolante;
- iii) Fluido escoando na máxima vazão permitida (15 kg/s) após a determinação da espessura de isolante da *flowline* para a menor vazão.

A autora observou condição de deslizamento entre as fases, conforme o comportamento ocorrido na realidade do escoamento devido à diferença entre os volumes ocupados pelas fases gás e líquido.

Apesar disso, apenas no segundo caso, o de menor vazão, o *holdup* de líquido calculado apresentou valores maiores que a fração volumétrica de líquido sem considerar o escoamento durante toda a extensão da linha de produção, conforme as condições reais de escoamento, mostrando que o modelo se adequa de maneira mais satisfatória quando as vazões que percorrem a linha de produção são menores.

II.4.1. Escoamento multifásico

Para o entendimento do modelo desenvolvido a ser utilizado para estimação de estados, faz-se necessária, previamente, a compreensão de determinados conceitos e fenômenos que se apresentam quando se trata do escoamento de fluidos durante a produção de óleo e gás no decorrer das linhas de produção.

O escoamento multifásico ocorre quando duas ou mais fases escoam em uma tubulação simultaneamente, que se mostram separadas graças a diferenças de densidade e imiscibilidade.

Tal comportamento gera diferentes tensões de cisalhamento nas paredes das tubulações nas porções em que escoam cada parte. É importante, ainda, ressaltar, que devido à diferença da expansão volumétrica entre porções de gás e líquido, as velocidades de escoamento das frações são diferentes, o que resulta em deslizamento entre as fases.

Em uma mistura bifásica, em condições de temperatura e pressão apropriadas, a transferência de massa ocorre continuamente (BAI & BAI, 2005), gerando as condições delimitadas pelo envelope observado no diagrama de fases, conforme apresentado na Figura 3, para uma mistura típica de hidrocarbonetos em condições de reservatório.

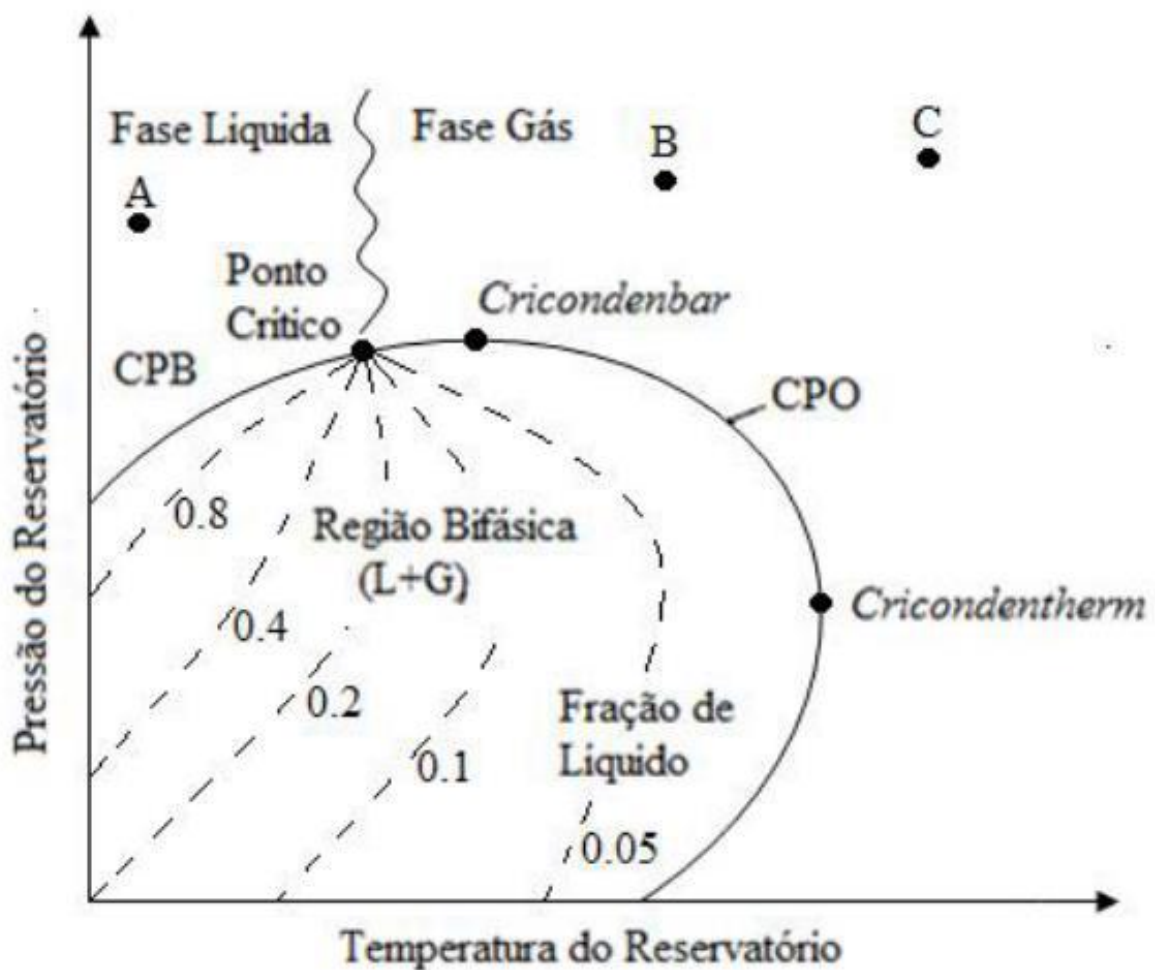


Figura 3: Envelope de fases de mistura bifásica de hidrocarbonetos em condições de reservatório. Fonte: Guedes (2015).

No diagrama observam-se as curvas de ponto de bolha (CPB) e de ponto de orvalho (CPO), além do ponto crítico da mistura, que delimitam o envelope da mistura bifásica, juntamente aos pontos *cricodentherm* e *cricondenbar*, que representam, respectivamente, as

maiores temperatura e pressão que duas fases coexistem em equilíbrio (ARCHER & WALL, 1986).

São observados cinco tipos distintos de reservatórios, que variam de acordo com a composição dos hidrocarbonetos presentes, o que leva a mudanças no formato do envelope de fases (ARCHER & WALL, 1986). De acordo com Bai & Bai (2005) os reservatórios podem ser classificados de acordo com os seguintes critérios:

- i) *Black oils*: rico em óleo pesado constituído por variadas espécies de hidrocarbonetos, incluindo hidrocarbonetos grandes e não voláteis. É transportado na fase líquida nas linhas de transporte e em regime bifásico nas linhas de produção;
- ii) *Óleos voláteis*: possuem maior quantidade de moléculas com até 6 carbonos em comparação aos *black oils* e possuem poucas moléculas pesadas (fração C7+, formada pelos pseudocomponentes) em sua composição. Dentro do reservatório se apresenta na forma de mistura binária, formando grandes frações de gás sob redução de pressão;
- iii) Gás condensado ou retrógrado: no início da produção, o fluido se apresenta na forma de gás e, com o decréscimo da pressão em seu interior, dado o avanço da produção, é formado líquido. Encontra-se em condições conforme a representada pelo ponto B na Figura 3;
- iv) Gases úmidos: o reservatório apresenta mistura em fase gasosa durante todo o período de exploração, mas com a queda de pressão e temperatura observadas nas porções *flowline* e no *riser* da linha de produção, há formação de mistura bifásica. Caracteriza-se por condições conforme as apresentadas pelo ponto C da Figura 3;
- v) Gases secos: comporta-se de maneira semelhante aos gases úmidos no interior do reservatório, mantendo-se na fase gasosa durante todo o horizonte de produção, porém não há formação de hidrocarbonetos líquidos em nenhuma etapa da produção. O reservatório é composto principalmente por gás metano.

Além dos hidrocarbonetos leves e pesados observados no interior dos reservatórios também há, em geral, a presença de água, nitrogênio, dióxido de carbono e sulfeto de hidrogênio. Além disso, os componentes da fração pesada, aquela composta por moléculas com número de carbono superior ou igual a 7, são, em geral, agrupados como “pseudocomponentes” (WHITSON & BRULE, 2000).

Para o correto entendimento das limitações do modelo a ser apresentado, também é interessante que se conheçam os tipos de escoamento possíveis nas tubulações, que variam de acordo com propriedades dos fluidos e das tubulações. Os tipos de regime de escoamento existentes para escoamentos vertical ou horizontal podem ser do tipo intermitente, que se divide em escoamento em bolhas, em névoa, em golfada, escoamento pistonado e escoamento agitado; ou escoamento segregado, podendo ser do tipo anular ou estratificado, de acordo com o reportado por Thome (2010).

O escoamento estratificado é caracterizado pela presença de líquido escoando ao fundo de uma tubulação horizontal e gás escoando sobre a interface gás-líquido. Pode ser classificado como suave ou ondulado, sendo o segundo decorrente de altas velocidades de gás, que gera a formação de ondas que se movem na direção do escoamento. Se as ondas formadas são altas o suficiente para causar o bloqueio da tubulação, formam-se golfadas suaves se movendo com velocidade média acima da velocidade de líquido.

Já o escoamento pistonado ocorre dado o aumento da velocidade de gás na tubulação, a partir do qual formam-se pistões de líquido separados por bolhas alongadas de gás, que se movem no superior da tubulação. Quando a velocidade do gás é ainda maior, o diâmetro das bolhas de gás é próximo ao diâmetro da tubulação, levando ao escoamento em golfadas, que pode causar severas vibrações no equipamento. Ao se aumentar mais a vazão de gás, forma-se um fino filme de líquido anular ao redor das paredes da tubulação, dando origem ao escoamento anular, com o gás escoando no centro. Finalmente, se a vazão de gás é ainda maior, ocorre o escoamento em névoa, no qual quase todo líquido é arrastado na forma de gotículas pela fase gás.

Quando a vazão mássica dos fluidos escoando na tubulação é elevada, é possível a formação do escoamento em bolhas (THOME, 2010). Nesse caso, o gás se move disperso na fase líquida, na forma de bolhas, podendo se concentrar próximo ao topo da tubulação, para vazões menores da fração líquida, ou na forma de bolhas no interior do líquido (FONTE, 2010).

II.4.2. Modelo de Beggs & Brill

O modelo de Beggs & Brill é um modelo semi-empírico capaz de prever o comportamento do escoamento bifásico em múltiplos ângulos de inclinação, levando em consideração o deslizamento entre as fases durante o escoamento e o padrão de escoamento para o cálculo do fator de atrito e do *holdup* de líquido (BEGGS & BRILL, 1973)

O estudo dos autores teve como objetivo o desenvolvimento de correlação para predição do *holdup* de líquido e do fator de atrito bifásico. Para tal, foram conduzidos 584 testes com ar e água escoando em tubulações de acrílico transparente com 27,43 m de comprimento e diâmetros de 0,03 e 0,04 m, para angulações de 0°, ±5°, ±10°, ±15°, ±20°, ±35°, ±55°, ±75°, ±85° e ±90° (BEGGS & BRILL, 1973).

Os autores preparam um mapa com base nos regimes observados no escoamento horizontal, dividindo-os em três categorias: escoamento segregado, escoamento intermitente e escoamento distribuído. O escoamento segregado conta com os fenômenos de escoamento estratificado, ondulado e anular; o intermitente é composto pelos escoamentos pistonado e em golfada; enquanto o escoamento distribuído pode ser do tipo em bolhas ou névoa. Houve uma modificação realizada no mapeamento original gerado por Beggs & Brill, levando em conta a inclusão de uma zona de transição entre os escoamentos segregado e intermitente (BRILL & MUKHERJEE, 1999).

Para a determinação da correlação do *holdup* de líquido (H_L) foram identificados diversos parâmetros significativos a serem levados em consideração, dentre os quais as relações entre o *holdup* e o ângulo de inclinação da tubulação, θ , o número de Froude, N_{FT} , e a fração volumétrica de líquido, desconsiderando-se o deslizamento entre as fases de escoamento, λ_L .

Foi determinado o fator de correção de inclinação, ψ , dado pela razão entre o *holdup* para um ângulo de inclinação qualquer, $H_L(\theta)$, com o *holdup* quando o ângulo é zero, $H_L(0)$. Além disso, foram obtidas correlações e coeficientes, identificados por a , b e c , para determinação do *holdup* de líquido para ângulo nulo de inclinação dadas variações no número de Froude e na fração volumétrica de líquido (Equações 2-24 e 2-25); além da relação entre as variáveis apresentadas e o fator de correção de inclinação (Equações 2-26 e 2-27).

$$H_L(0) = a\lambda_L^b N_{FT}^c \quad (2-24)$$

$$N_{FT} = \frac{v_m^2}{gd} \quad (2-25)$$

$$\psi = 1 + (1 - \lambda_L) \ln e \lambda_L^f N_{Fr}^g N_{Lv}^h \left[\sin(1,8\theta) - \frac{1}{3} \sin^3(1,8\theta) \right] \quad (2-26)$$

$$N_{Lv} = v_{SL} \left(\frac{\rho_L}{g\sigma_L} \right)^{\frac{1}{4}} \quad (2-27)$$

Finalmente, para o escoamento na região de transição entre os regimes segmentado e intermitente, o valor do *holdup* deve ser interpolado nos valores entre os dois regimes. O fator de atrito pode ser obtido com base no Diagrama de Moody, através de equações que diferem de acordo com o tipo de escoamento.

Apesar da robustez do modelo de Beggs & Brill, são constantemente utilizadas modificações e correções. Payne *et al.* (1979) sugeriram fatores de ajuste para o cálculo de *holdup* de líquido ascendente e descendente, sendo o *holdup* modificado equivalente a 92,4% do *holdup* calculado por Beggs & Brill, no caso de escoamento ascendente, e de 68,5% no caso do escoamento descendente.

Já para o cálculo do gradiente de pressão foram levados em consideração os efeitos da força de atrito, da elevação e da aceleração do fluido, sendo calculada de acordo com a Equação 2-28.

$$-\frac{dP}{dx} = \frac{f_{tp} \frac{\rho_n v_m^2}{2d} + \rho_{tp} g \text{sen}(\theta)}{1 - \frac{\rho_{tp} v_m v_{sg}}{P}} \quad (2-28)$$

II.4.3. Especificidades da resolução do modelo

Durante o desenvolvimento do modelo proposto por Guedes (2015) foram originadas equações diferenciais, dadas as equações de conservação e restrições termodinâmicas. Para a resolução do sistema de equações algébrico-diferenciais (EADs) optou-se pela não conversão em equações diferenciais ordinárias devido ao esforço computacional elevado necessário para realização da abordagem. Foi observado também que para alterações bruscas nas condições de escoamento entre dois pontos o modelo proposto por Beggs & Brill apresentou grandes discontinuidades, fazendo-se necessária a mudança de valores dos coeficientes empíricos para o cálculo de *holdup*.

Dessa maneira, a autora optou pela implementação de funções de regularização desenvolvidas por Teixeira (2013), capazes de suavizar saltos descontínuos na inicialização de sistemas de EADs, evitando que os cálculos fossem prejudicados pelas discontinuidades.

Finalmente, é importante salientar que a abordagem considera que o poço é avaliado em condições iniciais de vida, sem que haja produção de água. Além disso, apesar do modelo apresentar algumas simplificações, o mesmo pode ser capaz de representar o sistema de escoamento de fluido multifásico satisfatoriamente por não remover informações essenciais ao seu comportamento (AARSNES *et al.*, 2016). Trata-se de um modelo estacionário, não isotérmico e que considera gás real por meio do fator de compressibilidade, apresentando com restrições de garantia de escoamento.

II.4.4. Implementação do modelo

A metodologia apresentada por Guedes (2015) inicia-se com o cálculo de propriedades chave para a resolução do sistema de EADs apresentado, resultante da implementação do modelo de Beggs & Brill.

Identificou-se, primeiramente, que se faz necessária a determinação das entalpias das fases, por sofrerem influência das variações de pressão e temperatura (TEIXEIRA, 2013). Além disso, a partir da equação para determinação do gradiente de pressão (Equação 2-28), é clara sua dependência com propriedades físicas do fluido, tais quais sua densidade, viscosidade e tensão superficial.

A partir de cálculos de Flash é determinada a fração vaporizada do fluido em cada posição axial avaliada, sendo possível a determinação das propriedades físicas necessárias (TEIXEIRA, 2013). As propriedades dos componentes puros são encontradas na literatura, porém no caso do pseudocomponente, constituinte da fração C7+, as propriedades devem ser calculadas. São conhecidas a massa molar (350 kg/kmol) e a densidade (870 kg/m³) do pseudocomponente, propriedades a partir das quais as demais são calculadas.

Primeiramente, a partir de simulações estacionárias, foram estabelecidos o diâmetro interno e nível de isolamento da *flowline*, com base de exigências quanto à mínima temperatura de saída na superfície e à máxima pressão de entrada na *flowline*. As simulações foram realizadas em seu trabalho para vazões de 5 e 15 kg/s, sendo a menor vazão responsável pela determinação do nível de isolamento necessário, e a maior, o diâmetro interno da *flowline*.

Em seguida, para os cálculos de equilíbrio líquido-vapor foi utilizado um método iterativo para determinação da fração molar vaporizada, β , e constante de equilíbrio, K . O valor inicial da constante de equilíbrio foi estimado a partir da correlação de Wilson, para o qual é necessário o conhecimento da temperatura e pressão críticas dos componentes, e do fator acêntrico. Para o valor inicial estimado, calcula-se o primeiro valor de fração molar vaporizada, dando início ao cálculo iterativo. A equação de Rachford-Rice foi usada como função objetivo no cálculo da fração molar vaporizada, recalculada até que uma determinada tolerância seja respeitada e a convergência atingida. Após determinado o valor da fração molar vaporizada, foi realizado o cálculo iterativo para determinação da vazão molar, por meio do balanço molar na unidade de Flash, para o qual faz-se necessária a determinação de uma equação de estado para o cálculo do coeficiente de fugacidade e do fator de compressibilidade.

O cálculo da entalpia para os componentes puros foi realizado a partir de uma função de afastamento do gás ideal, dada pela diferença entre a propriedade referente ao fluido real à

pressão P e aquela referente a um gás ideal na pressão P_o . Já o cálculo da entalpia do pseudocomponente foi utilizado o método de Stevens & Thodos (1963).

As propriedades críticas, pressão e temperatura, o fator acêntrico, densidades e viscosidades de líquido e gás do pseudocomponente foram calculados com base em correlações definidas por Riazi (2005) e a tensão superficial com base na correlação desenvolvida por Dauber & Danner (1997).

Devido a diferentes inclinações, comprimentos, diâmetros e existência de sistema de isolamento externo entre cada parte da linha de produção, deve-se dividi-la por frações da *riser*, *flowline* e as frações da seção final do poço. Isto pois a inclinação de cada porção da linha de produção resulta em diferentes parâmetros e coeficientes do modelo de Beggs & Brill, sendo necessária a segmentação das parcelas da linha de produção para que a implementação do modelo seja eficiente e convergente.

O modelo matemático desenvolvido por Guedes (2015) foi aplicado neste trabalho conforme descrito ao longo desta seção.

III. METODOLOGIA

III.1. Abordagem computacional

A execução do trabalho foi conduzida por meio de simulações do modelo do processo através do software *Environment for Modeling, Simulation and Optimization* (EMSO), integrado ao *Python* pela interface *emsopy*, via pela qual foi aplicado o algoritmo do Filtro de Kalman Estendido.

EMSO é um ambiente de simulação orientada por equações com linguagem própria de modelagem orientada a objetos, capaz de tratar de processos complexos, em regimes estacionários ou dinâmicos. Também é possível a criação de modelos inteiramente novos, utilizando sua linguagem própria, ou mesmo a utilização daqueles modelos disponíveis em sua biblioteca *open source* (EML, do inglês, EMSO Model Library).

Góes *et al.* (2021) propuseram um modelo implementado em EMSO para previsão de fluxos individuais de líquido e gás em poços de produção de petróleo e gás em tempo real. A escolha do ambiente se deu devido à sua capacidade de processar dados iniciais mesmo em grande quantidade com baixos tempos de simulação.

O ambiente possui interface de integração com demais tecnologias, tais quais MATLAB e Python, sendo esta última uma linguagem de programação de alto nível orientada a objetos, amplamente difundida devido à sua alta aplicabilidade a múltiplas aplicações, à existência de uma extensa gama de bibliotecas disponíveis e a simplicidade de escrita de código.

III.2. Aplicação do modelo

O modelo desenvolvido por Guedes (2015) foi aplicado sobre medidas realizadas entre os dias 01 e 15 do mês de abril de 2016, no poço de exploração de petróleo identificado como MLL-69, referentes à vazão volumétrica de *gas lift* (G_L) e pressão de tubo à montante (P_{sep}), e divididas em intervalos igualmente espaçados, de 2 h cada.

Foram fornecidas medidas acerca da pressão e temperatura no topo e fundo do poço. A diferenciação das medidas em cada posição se dá neste trabalho, respectivamente, pelos subscritos “TPT” (do inglês, *Temperature and Pressure Transmitter*) e “PDG” (do inglês, *Permanent Downhole Gauge*). Essas posições são avaliadas em aproximadamente 3623,8 m e 6226,5 m, respectivamente, a partir do encontro entre *flowline* e *riser*, sendo o comprimento total da linha de produção de 7145,5 m.

Os dados de pressão à montante e vazão de *gas lift* foram alimentados ao modelo, que conta com um total de 94421 equações e 96572 variáveis. Além disso, características gerais do poço e dos fluidos foram especificadas, de acordo com o exposto na Tabela 1.

Tabela 1: Parâmetros relativos ao poço MML-69.

Parâmetro	Valor	Parâmetro	Valor
API	27,67	Fração de água [%]	29
Densidade do óleo	0,889	Razão gás/óleo [m ³ /m ³]	81,2
Densidade do gás produzido	1,007	Pressão de tubo média [kgf/cm ²]	15
Densidade da água de formação	1,14	Comprimento total [m]	7147,5
Densidade do gás de formação	0,934	Pressão de saturação do reservatório [kgf/cm ²]	157,7
Densidade do gás de injeção	1,016	Temperatura do reservatório [K]	386,35
Vazão de injeção média [m ³ /h]	7000		

Fonte: Guedes *et al.* (2016).

A partir da simulação do modelo, foi possível a determinação de variáveis de saída de interesse, conforme exibidas na Tabela 2.

Tabela 2: Variáveis de saída de interesse do modelo desenvolvido por Guedes (2015).

Variável	Descrição
P_{PDG}	Pressão no fundo do poço
T_{PDG}	Temperatura do fundo do poço
P_{TPT}	Pressão no topo do poço
T_{TPT}	Temperatura no topo do poço

Devido a falhas ocorridas durante o período avaliado, foi realizado um tratamento dos dados obtido para garantia de uma avaliação mais criteriosa do modelo. Foi determinada, com base na observação do comportamento do conjunto de dados fornecido, uma tolerância de 15% ao redor da média de cada uma das medidas correspondentes às saídas do modelo de interesse ao trabalho, são elas, P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} . Dessa forma, todos pontos que se encontravam com valores inconsistentes, apresentando grande divergência dentre os demais, foram removidos do conjunto total de dados a serem avaliados.

Para a obtenção inicial dos resultados da simulação, o conjunto de dados foi dividido em quatro intervalos de avaliação, para cada um dos quais foi necessária a aplicação de diferentes conjuntos de estimativas iniciais. A identificação inicial dos intervalos se deu por tentativa e erro, que gerou a observação de que determinados conjuntos de dados não apresentavam convergência para o conjunto de estimativas iniciais padrão. Por observação do perfil temporal das medidas fornecidas foi possível constatar que, quando o conjunto apresenta divergência em relação ao valor médio do conjunto de dados anterior, há a necessidade de um

novo conjunto de estimativas iniciais. Dessa maneira, os intervalos foram definidos nos pontos onde há alguma mudança no comportamento das variáveis de entrada do processo.

O procedimento para geração dos conjuntos consistiu na realização de múltiplas simulações no ambiente EMSO, nas quais pequenas alterações consecutivas foram realizadas no valor de cada uma das variáveis de entrada por vez. Ao se observar que uma alteração foi grande o suficiente para divergir os resultados das estimativas iniciais sendo utilizadas, foi gerado um conjunto com os resultados da última simulação convergida. O conjunto gerado foi utilizado como a estimativa inicial das simulações seguintes, até que os valores de ambas as variáveis de entrada se encontrassem próximos ou iguais à média dos valores de entrada no conjunto de dados do intervalo avaliado.

III.3. Análise de sensibilidade

Foi avaliada a sensibilidade de cada uma das variáveis de saída de interesse do modelo em relação a variações em suas condições de entrada. Para tal avaliação, foi utilizado o método DAS (do inglês, *Differential Sensitivity Analysis*) de análise de sensibilidade diferencial, conforme descrito por Perlingeiro (2005). O processo é um método de análise de sensibilidade local, aplicado usualmente para a determinação de sensibilidade frente a pequenos desvios nas variáveis de entrada.

Sendo F a variável para a qual deseja-se determinar a sensibilidade a partir de um desvio em uma das variáveis de entrada do processo e ξ um parâmetro de valor desconhecido, a derivada de F em relação à ξ é capaz de determinar o efeito da incerteza de ξ sobre F , quando aplicada com todos os parâmetros e variáveis em seus valores base ($\bar{\xi}$).

Com valores relativos aos valores-base obtêm-se resultados que independem das unidades de medida de F e ξ , definindo-se assim a função de sensibilidade S de F em relação à ξ , conforme as equações que seguem:

$$S(F; \xi) = \left| \frac{\partial \left[\frac{F(\xi)}{F(\bar{\xi})} \right]}{\partial \left(\frac{\xi}{\bar{\xi}} \right)} \right|_1 = \left| \frac{\partial F(\xi)}{\partial \xi} \right|_1 \times \frac{\bar{\xi}}{F(\bar{\xi})} \quad (3-1)$$

A determinação da variação da variável F com o parâmetro ξ pode ser dada por sua aproximação numérica, na qual:

$$\frac{\partial F}{\partial \xi} = \frac{F(\bar{\xi} + \Delta\xi) - F(\bar{\xi})}{\Delta\xi} \quad (3-2)$$

Portanto,

$$S(F; \xi) = \frac{F(\bar{\xi} + \Delta\xi) - F(\bar{\xi})}{\Delta\xi} \times \frac{\bar{\xi}}{F(\bar{\xi})} \quad (3-3)$$

A função Sensibilidade de F sobre ξ pode ser reescrita da seguinte maneira:

$$S(F; \xi) = \frac{F(\bar{\xi} + \Delta\xi) - F(\bar{\xi})}{F(\bar{\xi})} \times \frac{\bar{\xi}}{\Delta\xi} \quad (3-4)$$

Para um incremento de 1 % sobre o valor-base, tem-se:

$$\frac{\Delta\xi}{\bar{\xi}} = 0,01 \quad (3-5)$$

$$S(F; \xi) = \frac{F(1,01\bar{\xi}) - F(\bar{\xi})}{F(\bar{\xi})} \times 100 \quad (3-6)$$

Valores médio de G_L e P_{sep} foram determinados com base no conjunto total de dados, sobre os quais foram aplicados incrementos de 1 % e 10 %. O incremento de 10 % foi realizado para avaliação do efeito de não linearidade do modelo que descreve o processo sobre as variáveis e validação dos resultados de sensibilidade obtidos com base no incremento de 1 %.

Ao fim foram realizadas cinco simulações apresentando diferentes combinações dos valores de G_L e P_{sep} . Primeiramente, as simulações foram realizadas com ambas as variáveis em seus valores base, e em seguida quatro simulações incrementando-se uma variável por vez, conforme os incrementos já descritos.

III.4. Aplicação do Filtro de Kalman Estendido

III.4.1. Estimação dos estados

De acordo com o descrito na Seção II.3.3, a aplicação do Filtro de Kalman Estendido se dá a partir da linearização do modelo dinâmico do processo, com base em sua representação em espaços de estados.

O algoritmo para emprego do Filtro de Kalman divide-se em duas etapas: predição e atualização, nas quais é utilizada para a estimativa no instante avaliado, de maneira recursiva, a estimativa da medida no instante de tempo anterior. Dessa forma, a matriz que descreve o processo, assim como a matriz de covariância de erro do processo são atualizadas a cada nova iteração, conforme esquematizado na Figura 4.

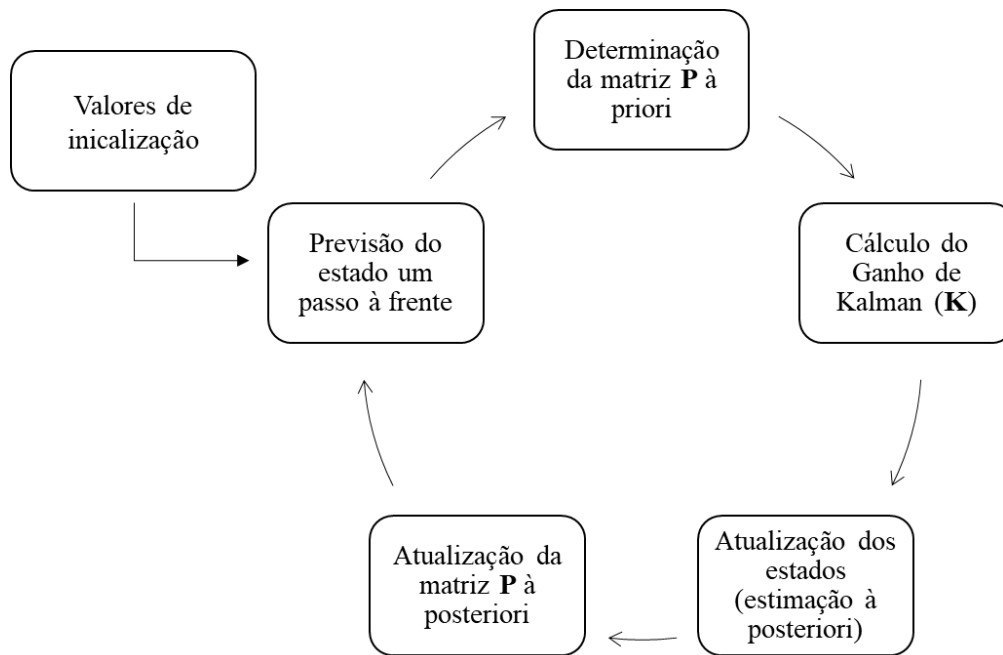


Figura 4: Esquema representativo da metodologia de implementação do Filtro de Kalman.

Ao mesmo tempo, o modelo desenvolvido por Guedes (2015) é de um processo que apresenta dinâmica rápida, tendo sido considerado o modelo estacionário tratado como um modelo de dinâmica instantânea. Sendo assim, a partir de dados de entrada no processo que variam com o tempo determina-se o valor das variáveis de interesse.

III.4.2. Sintonia das matrizes de covariância

A inicialização do Filtro de Kalman é uma etapa de extrema importância para garantir seu desempenho de forma eficiente e acurado. Essa fase é composta por, além da determinação de valores iniciais dos estados do sistema, permitindo a realização da primeira inferência; da determinação dos valores das matrizes de covariância que atuam como parâmetros de sintonia do filtro e representam a importância das medições realizadas e a confiabilidade do modelo proposto.

A matriz de covariância dos ruídos do processo é, usualmente, aquela que apresenta maior dificuldade de determinação. Isto porque ao seu valor somam-se erros dos sensores, usados para determinação de correlações empíricas utilizadas em sua implementação, e aqueles associados às aproximações realizadas para formulação do modelo matemático. Dessa forma, devido à ausência de informação e à dificuldade de determinação das covariâncias, em geral a matriz é representada de maneira diagonal, na qual as variâncias, que compõe a diagonal da

matriz, buscam representar o maior erro que pode existir em cada um dos estados do modelo (SCHURK *et al.*, 2017).

Nesse sentido, diversos trabalhos vêm sendo realizados visando a elaboração de metodologias capazes de determinar parâmetros de sintonia que reduzam ao máximo o erro associado a cada estimativa. Evolução Diferencial (DEA) e Evolução Diferencial Multi-Objetivo (MODEA) foram utilizadas associadas a diversas funções de adequação por Zerdalli & Barut (2017) para determinação de parâmetros ótimos de inicialização do filtro. Já Yin *et al.* (2017) foram capazes de reduzir o erro das estimativas do filtro a partir de uma sequência de múltiplos EKF.

Ainda assim, muitas vezes seus valores são determinados por tentativa e erro, principalmente quando não há conhecimento sobre o comportamento dinâmico do processo (RAYAMM *et al.*, 2018).

A matriz de covariância de incertezas da estimação, que é atualizada e ajustada no decorrer das iterações, aponta a incerteza inicial da variável de estado. Tipicamente, são atribuídos valores altos para uma convergência rápida, ou menores quando se visa a suavização da dinâmica (HAMISCH, 2021). Havendo conhecimento quanto ao erro promovido pelo modelo nos instantes iniciais é possível formulação eficiente de seus valores.

Finalmente, a matriz de covariância dos ruídos de medição pode ser obtida com base nos desvios padrões das variáveis avaliadas. Neste trabalho, o parâmetro é representado por uma matriz diagonal composta pelas variâncias apresentadas por cada uma das variáveis avaliadas no conjunto de dados de medidas fornecido, identificadas como \hat{A} , \hat{B} , \hat{C} e \hat{D} :

$$\mathbf{R}' = \begin{bmatrix} \sigma_{\hat{A}}^2 & 0 & 0 & 0 \\ 0 & \sigma_{\hat{B}}^2 & 0 & 0 \\ 0 & 0 & \sigma_{\hat{C}}^2 & 0 \\ 0 & 0 & 0 & \sigma_{\hat{D}}^2 \end{bmatrix} \quad (3-7)$$

Já para a determinação da matriz \mathbf{Q} , inicialmente foi a ela atribuído o valor da matriz identidade, \mathbf{I} , de dimensão igual ao total de estados do processo, como um valor base, e realizados testes a partir de sua multiplicação pelo parâmetro j , cujos valores foram variados entre 0,01, 0,05, 0,1 e 0,5, mantendo-se a matriz da covariância dos ruídos das medidas constante, conforme previamente apresentado. A matriz \mathbf{Q} não será apresentada pois o modelo possui alta complexidade, dado por 96572 variáveis e 77251 estados.

Dessa forma, temos que:

$$\mathbf{Q} = j\mathbf{I} \quad (3-8)$$

De maneira análoga à matriz de covariância dos ruídos, é possível a adoção da matriz formada pelas covariâncias dos estados a partir da simulação prévia do modelo. Foi calculada a covariância de cada um dos estados do processo após uma primeira simulação do modelo para um intervalo de tempo avaliado.

Além disso, também foi estabelecido um parâmetro escalar j , aplicado sobre a matriz, avaliado por duas perspectivas. Assim como realizado sobre a matriz \mathbf{I} , mantendo-se a matriz de covariância dos ruídos da medida constante; e permitindo a ponderação entre a influência dos ruídos da medida e do processo sobre o filtro ao ser aplicado sobre as matrizes \mathbf{Q} e \mathbf{R} , conforme as seguintes relações:

$$\mathbf{Q} = j\mathbf{Q}' \quad (3-9)$$

$$\mathbf{R} = (1 - j)\mathbf{R}' \quad (3-10)$$

Os mesmos valores dos testes ao redor da matriz identidade como valor base foram atribuídos à j .

Finalmente, os valores iniciais da matriz da covariância das incertezas da estimação foram mantidos fixos na forma de uma matriz diagonal na ordem de 10^4 , pois observa-se um *offset* razoável entre os valores medidos e os simulados.

A determinação da aderência do Filtro aos resultados foi dada com base na avaliação da raiz quadrada do erro quadrático médio (*REQM*), calculada conforme a Equação 3-11:

$$REQM = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3-11)$$

Em que n representa o número total de pontos avaliados no sistema, \hat{y}_i o valor da variável calculada seja pela simulação do modelo ou pela aplicação do Filtro de Kalman e y_i o valor real ajustado pela aplicação do Filtro.

IV. RESULTADOS E DISCUSSÃO

IV.1. Simulação do modelo

O processamento inicial dos dados fornecidos, considerando tolerância de 15% ao redor da média de cada uma das medidas durante o período avaliado, resultou na extração de 7 dentre as 169 medidas inicialmente disponíveis, conforme ilustram as Figuras 5 e 6, que apresentam os valores de todas as medidas fornecidas antes e após processamento. O total de valores removidos da análise representa 4,14% dos dados preliminarmente disponibilizados.

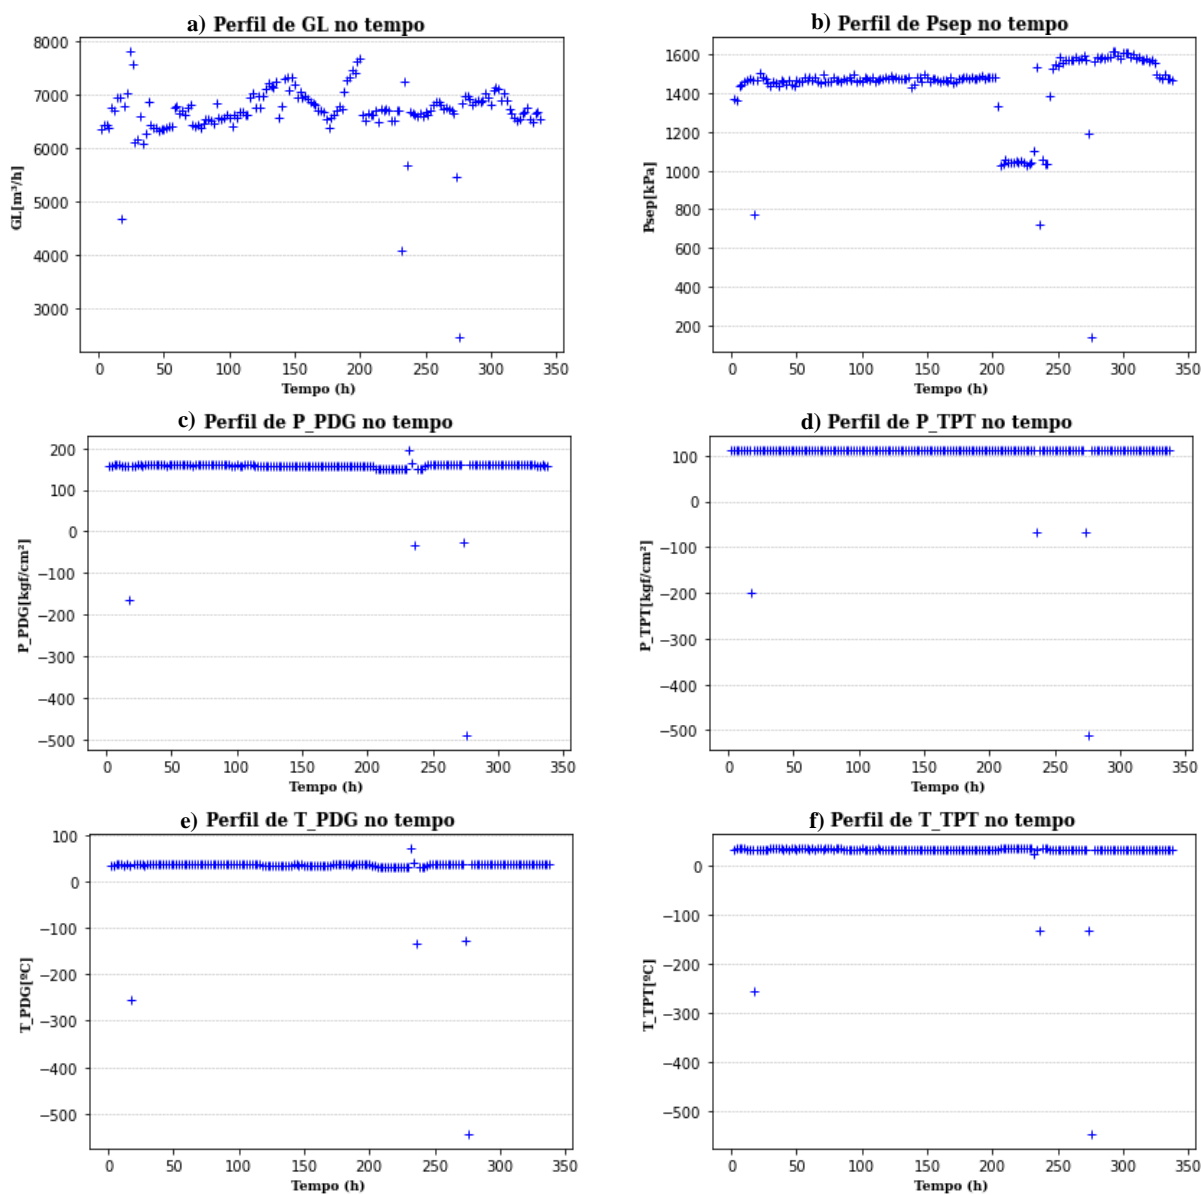


Figura 5: Representação do conjunto de dados fornecidos ao pré-processamento. a: vazão volumétrica de *gas lift*; b: pressão do tubo; c: pressão de fundo de poço; d: pressão de topo de poço; e: temperatura de fundo de poço; f: temperatura de topo de poço.

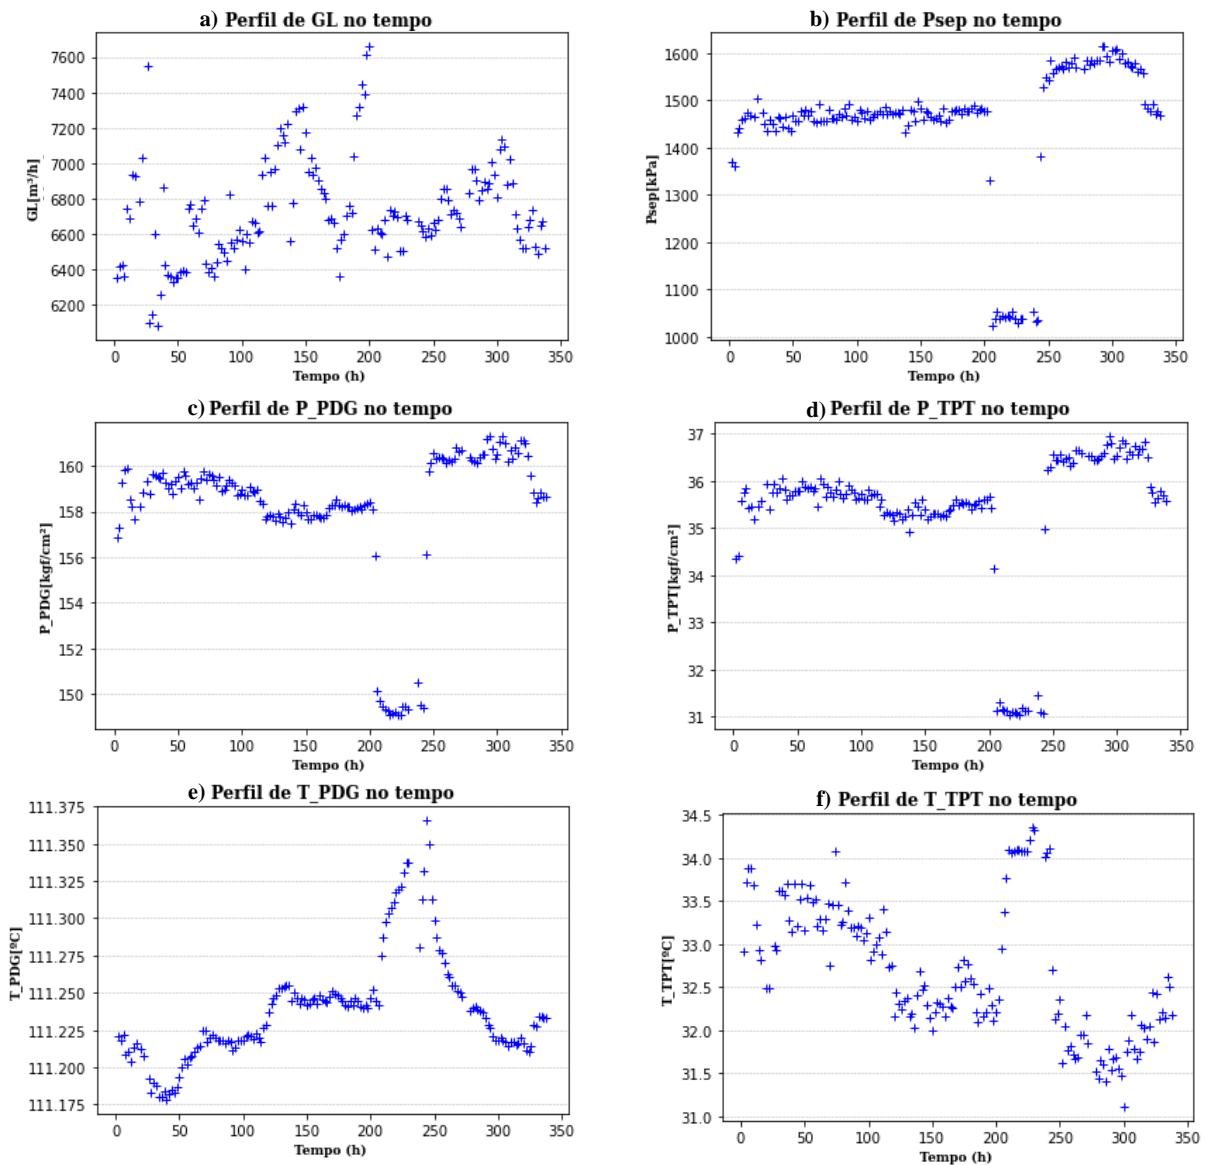


Figura 6 : Representação do conjunto de dados fornecidos após o pré-processamento. a: vazão volumétrica de *gas lift*; b: pressão do tubo; c: pressão de fundo de poço; d: pressão de topo de poço; e: temperatura de fundo de poço; f: temperatura de topo de poço.

Tomando como base apenas a observação do comportamento das medidas é justo supor que os desvios causados pelos pontos removidos não representam o estado real de cada uma das temperaturas e pressões no momento no qual foram determinadas. Isto pois os valores se apresentam como variações súbitas, ocorridas em pontos isolados dentro do período observado, não impactando na avaliação da aderência do Filtro de Kalman sobre o conjunto de dados. Comportamento diferente é observado pelo intervalo entre os pontos 100 e 120 (200 h e 240 h), nos quais há ocorrência de uma variação brusca nas medidas – chegando a -6,37% da média das medições prévias para a pressão no topo do poço – porém que se estende de forma

aproximadamente constante pelo período observado de cerca de 40 h, caracterizando uma mudança na condição operacional.

Dessa forma, o pré-processamento busca garantir uma base dados com impacto positivo sobre a execução do trabalho, evitando desvios espúrios, ao se considerar um comportamento esperado mais próximo do real para as variáveis do poço na determinação das matrizes das covariâncias das medidas e dos estados do processo durante a etapa de sintonia do filtro. Além disso, o pré-processamento evita falhas de convergência do modelo devido a dados de entrada inconsistentes.

Por fim, para que se alcançasse a convergência do modelo para todos os pontos foi necessária a divisão dos dados em intervalos, identificados com base em mudanças abruptas no comportamento do perfil das variáveis de entrada. Os intervalos identificados encontram-se especificados na Tabela 3.

Tabela 3: Divisão dos dados em intervalos.

Intervalo	Início (h)	Fim (h)
1	0	204
2	204	242
3	242	306
4	306	338

Para cada um dos intervalos foi gerada um conjunto das estimativas iniciais próximos à média do conjunto de dados referentes a cada intervalo. Na Tabela 4 encontram-se, para cada intervalo, os valores utilizados para geração dos conjuntos de estimativas iniciais.

Tabela 4: Relação entre os valores de G_L e P_{sep} utilizados na geração das estimativas iniciais e seus valores médios em cada intervalo determinado.

Intervalo	G_L (m³/h)	G_L médio (m²/h)	P_{sep} (kPa)	P_{sep} médio (kPa)
1	7100,00	6734,730	1510,00	1460,096
2	6635,02	6634,276	1024,35	1166,888
3	6738,58	6850,556	1570,51	1583,986
4	7100,00	6604,057	1510,00	1498,693

A Figura 7 apresenta a divisão das medidas, realizada durante a execução da simulação inicial dos resultados sobre cada uma das medidas disponibilizadas da planta, após pré-processamento. Observa-se na figura a variação apresentada pelas medidas em cada intervalo.

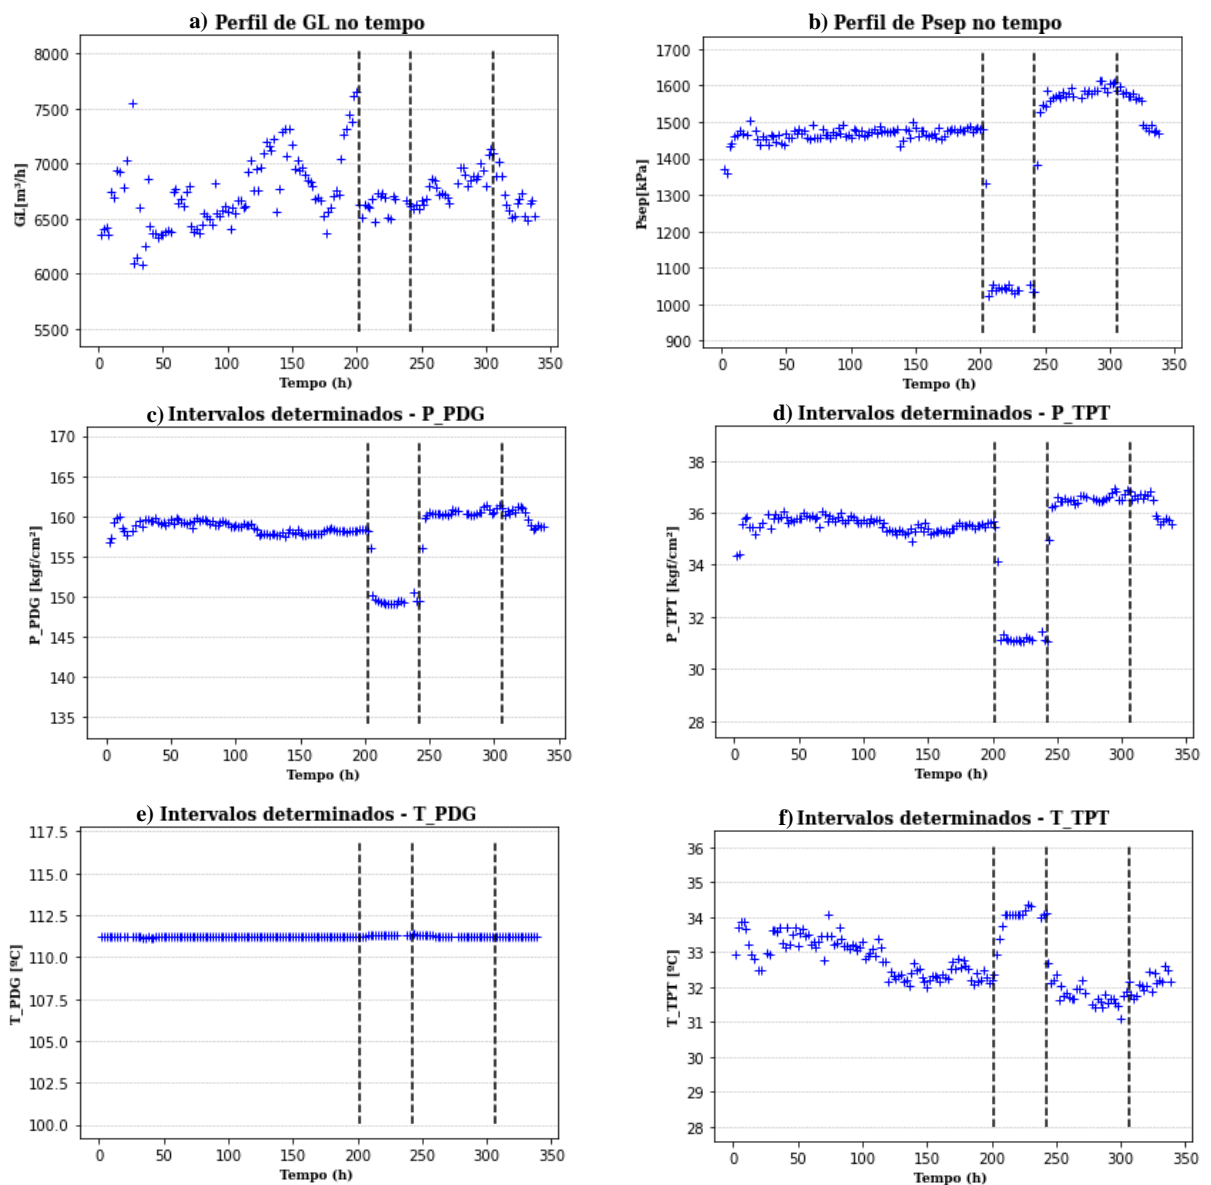


Figura 7: Identificação dos intervalos sobre cada uma das medidas. a: vazão volumétrica de *gas lift*; b: pressão do tubo; c: pressão de fundo de poço; d: pressão de topo de poço; e: temperatura de fundo de poço; f: temperatura de topo de poço.

Ao fim do processo, foram identificados três pontos no conjunto inicial de dados que não apresentaram convergência, mesmo sob a utilização de um conjunto de estimativas iniciais apropriado. Esses pontos, portanto, foram removidos da análise, resultando em 159 valores.

Na Figura 8 a seguir se observa os resultados da simulação do conjunto de dados resultantes, juntamente às medidas fornecidas no período. É possível observar que o modelo possui boa adequação ao acompanhar a tendência dos dados medidos, porém com determinado *offset* em relação a eles.

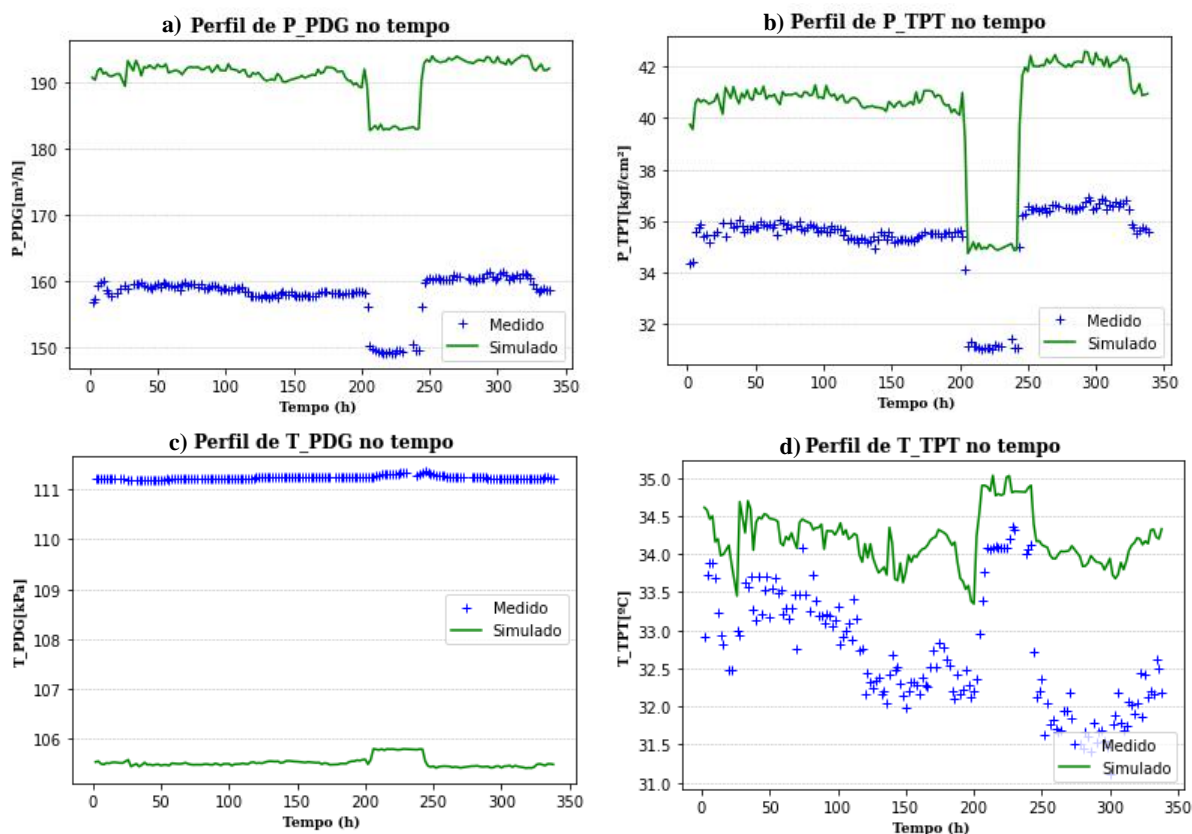


Figura 8: Comparação entre as medidas da planta e as respostas o modelo. a: variação da pressão no fundo do poço com o tempo; b: variação da pressão de topo de poço com o tempo; c: variação da temperatura de fundo de poço com o tempo; d: variação da temperatura de topo de poço com o tempo.

Na Tabela 5 estão apresentadas as raízes quadradas dos erros quadráticos médios de cada uma das variáveis de interesse em relação aos dados originais, além de suas respectivas médias, *offsets* médios, *offsets* médios relativos, valores mínimos e máximos e desvios padrões apresentados em cada caso. Os *offsets* médios foram calculados pela média dos *offsets* de cada ponto simulado em relação à medida da planta, enquanto os *offsets* médios relativos são dados pela razão entre o *offset* médio e a média do conjunto de dados.

Tabela 5: Raiz quadrada do erro quadrático médio, *offsets* médios, média, desvio padrão, valores máximo e mínimos para P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} simulados.

Variável	P_{PDG} (kgf/cm ²)	T_{PDG} (°C)	P_{TPT} (kgf/cm ²)	T_{TPT} (°C)
REQM	33,026	5,718	5,158	1,572
Offset médio	33,019	-5,718	5,131	1,471
Offset médio relativo	0,209	0,051	0,145	0,045
Média	191,121	105,521	40,473	34,181
Desvio padrão	2,891	0,098	1,965	0,343
Mínimo	182,781	105,412	34,746	33,344
Máximo	194,151	105,799	42,586	35,029

A partir da avaliação de *offset* médio relativo mensura-se a dimensão do *offset* sobre as medidas de pressão e temperatura, proporcionalmente à sua escala. Assim, é possível perceber que a divergência entre valores simulados e medidas da planta se faz mais impactante sobre ambas as medidas de pressão.

Observa-se também, na Tabela 5, que a inferência de pressão no fundo do poço por parte do modelo, dentre todas as demais variáveis calculadas, é a que apresenta maior *REQM*, apresentando grande diferença em relação aos resultados esperados. O menor valor previsto pelo modelo é cerca de 12% maior que o maior valor medido experimentalmente.

As aproximações e considerações realizadas durante a criação do modelo podem justificar o *offset*, como a de que o poço se encontraria em condições iniciais de vida, apresentando pouca ou nenhuma produção de água, conforme discutido nas Seções II.4.3 e II.4.4. No caso da pressão no fundo do poço, há ainda a dificuldade de modelagem e representação do fluido nas condições extremas presentes em tal ambiente, que se reflete também em um maior *offset* na determinação da temperatura à mesma altura do poço em comparação com a temperatura no topo.

Contudo, as previsões do modelo não linear para valores distintos de vazão volumétrica de *gas lift* e pressão no tubo – que variam entre 6084,612 m³/h e 7659,000 m³/h e 1024,347 kPa e 1614,013 kPa, respectivamente – apresentam desvios padrões e tendências de comportamento muito semelhantes ao observado nas medidas do poço, indicando que o modelo pode ser utilizado para tais inferências.

IV.2. Análise de sensibilidade

A análise de sensibilidade foi realizada sobre as variáveis de saída avaliadas do modelo, de acordo com o procedimento descrito na Seção III.3, para incrementos de 1% e 10% sobre valores médios de G_L e P_{sep} .

Os valores calculados para cada variável de saída do modelo em cada um dos cenários descritos encontram-se exibidos na Tabela 6. A base para realização da análise de sensibilidade são os valores apresentados como “Incremento (%) 0”, no qual $G_L = 6423,280$ m³/h e $P_{sep} = 1433,064$ kPa.

Tabela 6: Resposta de cada uma das variáveis de saída do modelo sobre incrementos individuais de 1% e 10% nos valores de G_L e P_{sep} .

Incremento (%)	0	1	10	1	10
	-	P_{sep}		G_L	
G_L (m ³ /h)	6423,280	6423,280	6423,280	6487,513	7065,608
P_{sep} (kgf/cm ²)	1433,064	1447,395	1576,370	1433,064	1433,064
P_{PDG} (kPa)	188,137	188,412	190,818	187,930	186,232
T_{PDG} (K)	378,649	378,639	378,546	378,656	378,715
P_{TPT} (kPa)	39,786	39,981	41,709	39,720	39,189
T_{TPT} (K)	307,607	307,586	307,411	307,554	307,062

Os valores da função S associada à sensibilidade de cada uma das variáveis com os parâmetros de entrada, dadas as variações nas entradas nos quatro casos discutidos, são apresentados na Tabela 7.

Tabela 7: Sensibilidade de cada variável de saída do modelo sobre incrementos individuais de 1% e 10% nos valores de G_L e P_{sep} .

S	G_L (1%)	G_L (10%)	P_{sep} (1%)	P_{sep} (10%)
$S(P_{PDG}; \xi)$	0,110	0,101	0,146	0,142
$S(T_{PDG}; \xi)$	0,002	0,002	0,003	0,003
$S(P_{TPT}; \xi)$	0,167	0,150	0,488	0,483
$S(T_{TPT}; \xi)$	0,017	0,018	0,007	0,006

De acordo com a avaliação dos resultados observa-se uma maior sensibilidade das pressões tanto para variações de G_L quanto a variações de P_{sep} .

Observa-se primeiramente que a variação da temperatura do fundo do poço, T_{PDG} , dentre as quatro variáveis para as quais são disponibilizadas medidas, apresenta baixa sensibilidade à variação de G_L e de P_{sep} , dentro do intervalo testado. Como essa é uma variável de interesse do estudo, foi considerada marginalmente significativa, e portanto, faz sentido que também sejam consideradas todas as variáveis que apresentam alguma sensibilidade à G_L e à P_{sep} maiores que aquela apresentada por T_{PDG} . Sendo assim, ao se estabelecer que T_{PDG} é suficientemente sensível às variações nas entradas para que seu estudo seja conduzido, também são suficientemente sensíveis todas aquelas que apresentarem variações maiores a essas variáveis.

Finalmente, os resultados da análise de sensibilidade também são capazes de responder e quantificar dois cenários previamente observados:

- i) Os *offsets* relativos à média das medidas apresentarem valores maiores para as pressões no fundo e topo do poço do que as respectivas temperaturas. Para o caso

do topo do poço e um incremento de 1% sobre o valor de P_{sep} , a sensibilidade da pressão é cerca de 70 vezes maior que a da temperatura, enquanto no fundo do poço esse valor é cerca de 50 vezes superior. Por isso, os resultados relativos à inferência da pressão tornam-se mais suscetíveis à influência de erros e incertezas de medição do que as temperaturas, além de que variações pequenas nas entradas provocam um efeito muito mais evidente na inferência das pressões.

- ii) A observação de que dentre as variáveis de entrada, a que determina a geração dos conjuntos de estimativas iniciais durante a simulação do modelo é a variação da P_{sep} . Observou-se que variações da ordem de 10^3 sobre G_L não impactavam necessariamente na convergência do modelo, enquanto variações da ordem de 10^2 sobre P_{sep} já eram capazes de gerar a necessidade de novos estimativas iniciais das medidas. Por isso, apesar de os valores de G_L apresentarem grande variação no tempo, conforme pode ser observado na Figura 6, os intervalos utilizados para geração dos conjuntos de estimativas iniciais basearam-se nas mudanças de P_{sep} . Com base na análise de sensibilidade entende-se de maneira numérica a maior influência das variações de P_{sep} sobre as variáveis de resposta do processo.

IV.3. Aplicação do Filtro de Kalman Estendido

Os cenários descritos na Seção III.4.2 foram avaliados, e para cada um determinou-se como principal fator de avaliação da aplicabilidade do filtro o valor da raiz quadrada do erro quadrático médio associado à relação entre as medidas da planta e os valores em cada ponto previstos com base na filtragem.

A matriz de covariância dos erros das medidas foi definida como uma matriz diagonal composta pelas variâncias de P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} , respectivamente, assumindo a seguinte forma:

$$\mathbf{R}' = \begin{bmatrix} 9,514 & 0 & 0 & 0 \\ 0 & 0,001 & 0 & 0 \\ 0 & 0 & 2,234 & 0 \\ 0 & 0 & 0 & 0,600 \end{bmatrix} \quad (4-1)$$

A variação com o tempo das variáveis principais no caso em que \mathbf{Q} é igual à matriz identidade e demais variações do valor de j encontram-se nas Figura 9 e Figura 10, para $j = 1$ e j variando entre 0,01 e 0,5, respectivamente.

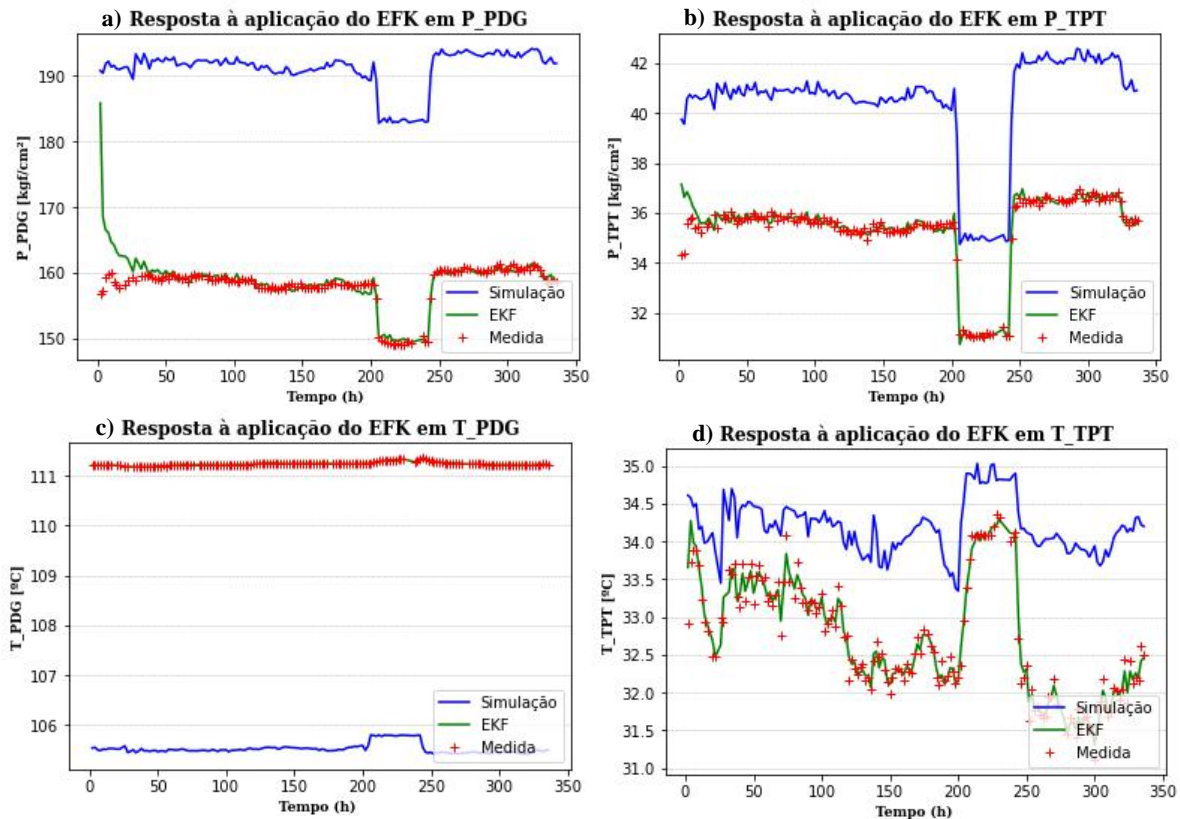


Figura 9: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = I$. a: pressão de fundo de poço; b: pressão de todo de poço; c: temperatura de fundo de poço; d: temperatura de topo de poço.

Na Figura 10 são exibidos os perfis comparativos da temperatura do fundo do poço sob a influência do filtro, sem a influência do mesmo e os valores medidos, para cada uma das variações de Q descritas nesse cenário. É importante salientar que os principais resultados do EKF para as temperaturas e pressões, de fundo e topo de poço, se encontram no texto para o caso em que Q é igual à matriz identidade, porém apenas o gráfico referente à pressão de fundo de poço é apresentado para os demais casos, nos quais j varia de 0,01 a 0,5. Os resultados para as demais variáveis podem ser encontrados no Apêndice I deste documento.

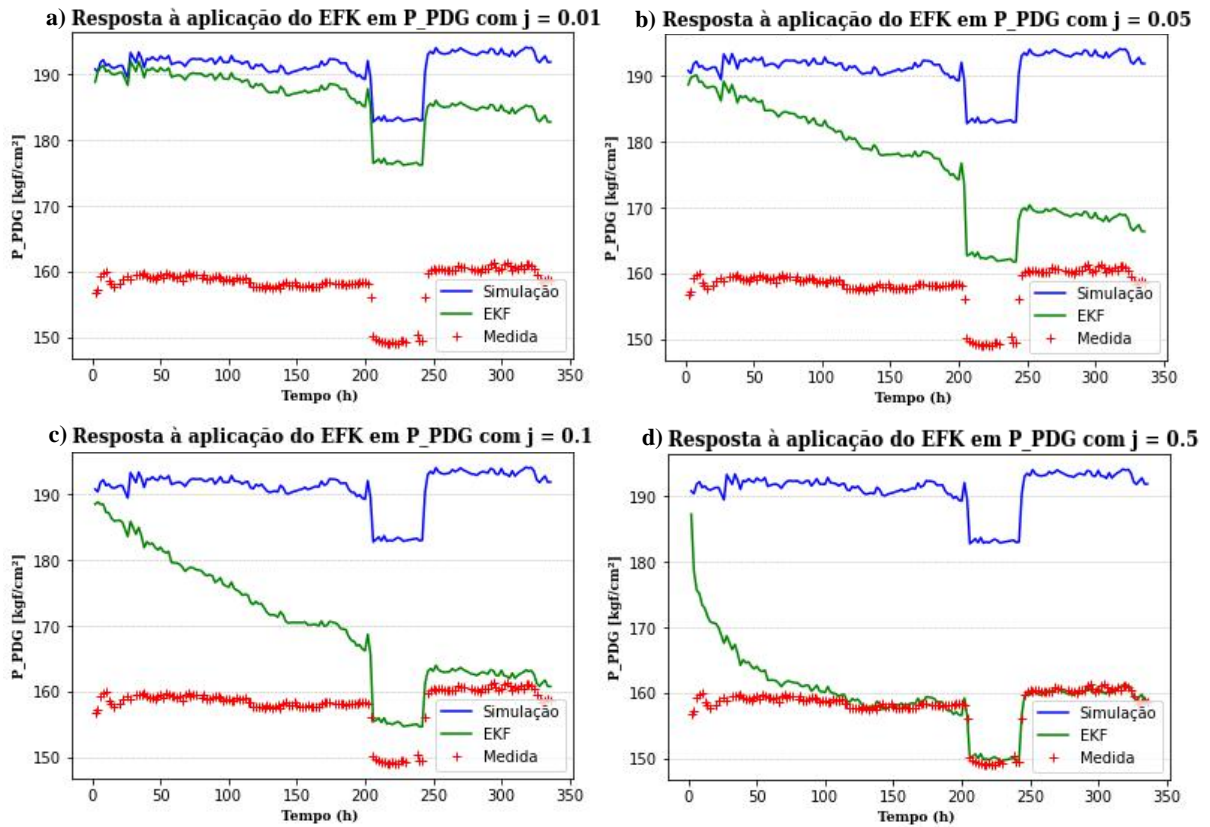


Figura 10: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $\mathbf{Q} = \mathbf{I}$. a: caso em que $j = 0,01$; b: caso em que $j = 0,05$; c: caso em que $j = 0,1$; d: caso em que $j = 0,5$.

Os resultados do EKF comportam-se conforme o esperado para todos os casos avaliados, tanto de P_{PDG} quanto das demais variáveis, apresentando melhor ajuste para maiores valores do multiplicador da matriz de covariância dos ruídos do processo. Tal comportamento se deve ao fato de que a matriz \mathbf{Q} representa a incerteza quanto às determinações realizadas pelo modelo. O aumento no valor das covariâncias, causado pelo aumento do multiplicador j , indica que pode haver grandes desvios nos valores sugeridos a partir da modelagem matemática do processo, fazendo com que o filtro seja mais fortemente influenciado pelas medidas reais do processo e tenda a convergir mais rapidamente.

Já em relação ao caso base, no qual o parâmetro j é igual à 1, é observado um comportamento satisfatório em relação à aplicação do Filtro de Kalman, apesar dos perfis apresentarem alguma oscilação ao redor das medidas reais da planta, mais fortemente observadas no caso das pressões, e influenciada pela ação do modelo.

Nesse sentido, ao se examinar os resultados apresentados na Figura 10, há a presença de um pico no ponto onde ocorre uma mudança brusca na medição da pressão, cerca de 200 h, que também é observado no resultado da simulação do modelo, em azul. O pico tende a diminuir e apresentar uma mudança de comportamento mais suave com o aumento de j , sendo razoavelmente reduzido no caso em que j é igual à 1. Comportamento semelhante é observado no caso das demais variáveis, com exceção da temperatura no fundo do poço, que apresenta boa convergência mesmo para o caso em que j é igual a 0,01, indicando que não apresenta alta covariância. Para fins de comparação com os demais ajustes do filtro, na Tabela 8 são apresentados alguns parâmetros relativos aos dados que sofreram ação do filtro.

Tabela 8: Raiz quadrada do erro quadrático médio, média, desvio padrão e valores de máximo e mínimo de P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} para cada valor do parâmetro j estudado quando Q é igual à I .

	P_{PDG} (kgf/cm ²)	T_{PDG} (°C)	P_{TPT} (kgf/cm ²)	T_{TPT} (°C)
$j = 1$				
<i>REQM</i>	2,826	0,001	0,369	0,134
Média	158,733	111,238	35,403	32,726
Desvio Padrão	4,026	0,036	1,540	0,771
Mínimo	185,853	111,365	37,150	34,288
Máximo	149,365	111,178	30,741	31,301
$j = 0,5$				
<i>REQM</i>	4,786	0,002	0,565	0,192
Média	160,073	111,238	35,478	32,736
Desvio Padrão	5,420	0,036	1,623	0,772
Mínimo	149,626	111,178	30,600	30,600
Máximo	187,277	111,365	38,035	34,440
$j = 0,1$				
<i>REQM</i>	14,609	0,010	1,480	0,342
Média	170,104	111,237	36,157	32,795
Desvio Padrão	9,134	0,037	2,207	0,741
Mínimo	154,640	111,117	30,120	31,449
Máximo	188,849	111,362	40,345	34,592
$j = 0,05$				
<i>REQM</i>	19,655	0,017	2,129	0,415
Média	176,260	111,237	36,896	32,862
Desvio Padrão	8,239	0,040	2,418	0,699
Mínimo	161,771	111,059	30,392	31,574
Máximo	190,137	111,359	40,830	34,720
$j = 0,01$				
<i>REQM</i>	28,450	0,055	4,143	0,669
Média	186,413	111,232	39,364	33,231
Desvio Padrão	3,998	0,068	2,141	0,574
Mínimo	176,190	110,600	33,184	32,171
Máximo	192,022	111,338	41,515	34,836

A raiz quadrada do erro quadrático médio foi o principal parâmetro utilizado para verificação da consistência da aplicação do filtro. A avaliação dos dados apresentados permite reafirmar os dois principais pontos anteriormente discutidos, sendo estes:

- i) O aumento no valor do parâmetro j reflete na convergência mais rápida das previsões realizadas pelo Filtro de Kalman, com *REQM* apresentando diferenças de aproximadamente 10, 44, 11 e 5 vezes entre as avaliações dos conjuntos preditos com j iguais a 1 e 0,01;
- ii) A redução dos valores que compõe a matriz de covariância dos ruídos do processo leva à maior presença de ruído nos valores previstos, confirmados pelas variações nos desvios padrões das variáveis, muito mais agudas para o caso de P_{PDG} .

O segundo cenário avaliado é aquele no qual a matriz \mathbf{Q} é uma matriz diagonal composta pelas variâncias do ruído do processo medidas previamente, dadas as simulações do modelo realizadas, e \mathbf{Q} é dada pelo produto entre \mathbf{Q}' e j .

Nesse caso espera-se que o filtro alcance um estado capaz de minimizar a função erro quadrático médio das variáveis do sistema para valores menores do que aqueles apresentados no caso em que $\mathbf{Q} = j\mathbf{I}$, no qual o ruído seja reduzido ao redor do ponto médio em cada caso. Além disso, assim como o comportamento observado no caso anterior, apresenta convergência mais lenta conforme se reduz o valor de j .

A resposta das variáveis principais avaliadas quando j é igual a 1 encontram-se na Figura 11.

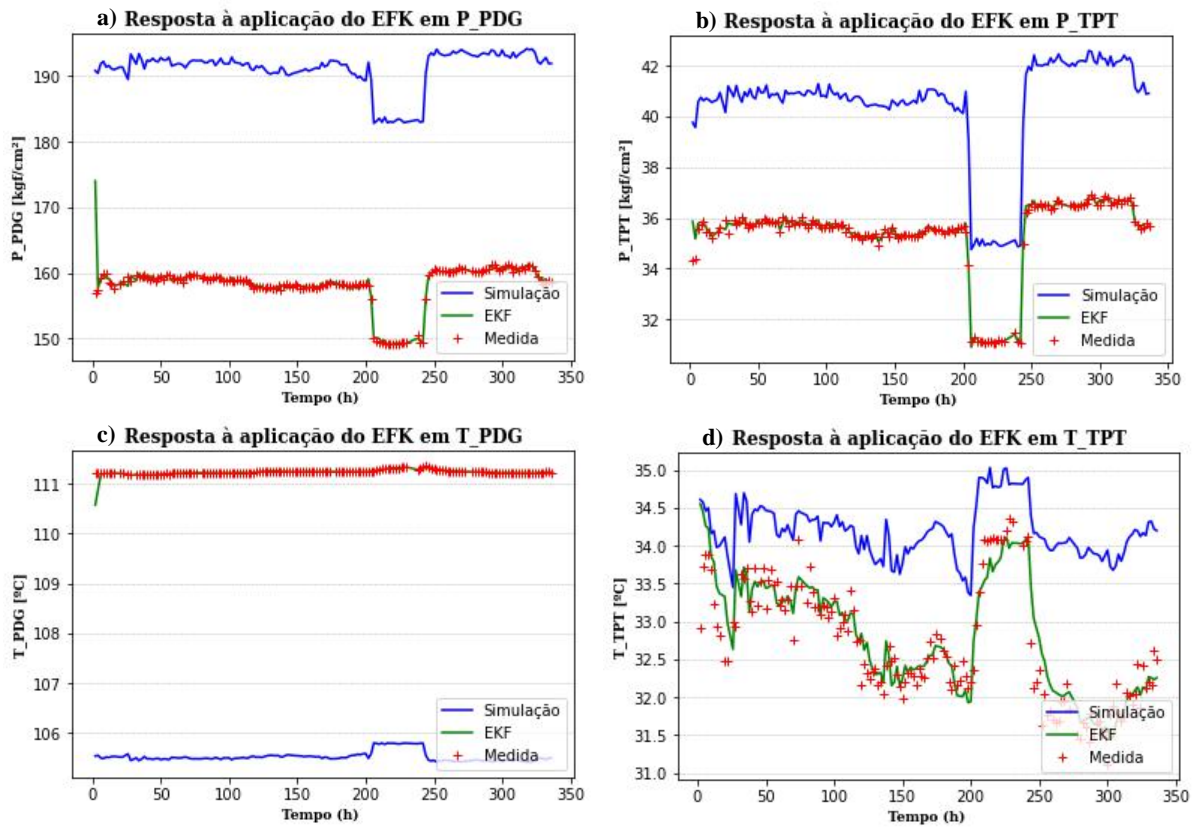


Figura 11: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = jQ'$. a: pressão de fundo de poço; b: pressão de todo de poço; c: temperatura de fundo de poço; d: temperatura de topo de poço.

Na sequência são apresentados na Figura 12 os resultados do EKF com as previsões com $Q = jQ'$. São exibidos no texto, assim como realizado no caso anterior, apenas os resultados da pressão de fundo de poço, variável que apresenta maior diferença de convergência em cada caso, podendo os demais casos serem averiguados no Apêndice II deste trabalho.

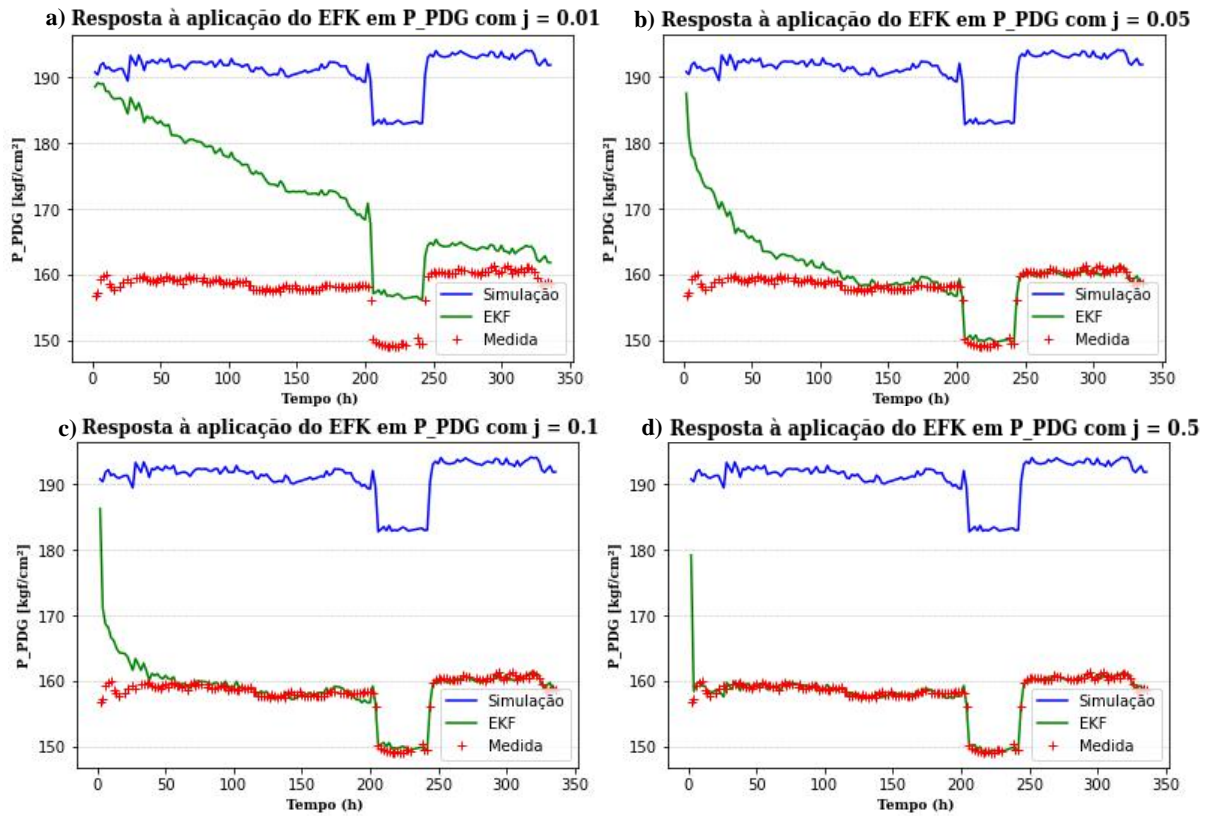


Figura 12: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = jQ'$. a: caso em que $j = 0,01$; b: caso em que $j = 0,05$; c: caso em que $j = 0,1$; d: caso em que $j = 0,5$.

Com base na observação dos resultados obtidos em cada um dos casos, reafirma-se que, também para esse cenário, a redução de Q provoca maior ruído sobre a resposta e menor velocidade da convergência da predição das medidas.

Além disso, é interessante pontuar o efeito da matriz de covariância das incertezas da estimação sobre a convergência de cada uma das variáveis. Conforme discutido nas Seções II.3.1 e III.4.2, a matriz P_0 reflete a incerteza da estimação inicial, e a ela foi atribuído o valor do produto entre a matriz I e 10^4 , sugerindo que há incerteza relativamente alta na estimativa do valor de inicialização do filtro. Ao mesmo tempo, nota-se que as variâncias relativas às determinações das temperaturas são muito menores do que das pressões.

Nesse sentido, o resultado da simulação do filtro apresenta uma convergência bem mais rápida e estimativas iniciais muito mais próximas do resultado obtido pelo modelo para as temperaturas do que para as pressões. No caso base, no qual j é igual a 1, enquanto o primeiro ponto determinado pela ação do filtro para a pressão no fundo do poço resulta em uma diferença de cerca de 8,9% em relação ao valor da medida, no caso da temperatura do fundo do poço essa

diferença é de aproximadamente 0,5%, se afastando muito mais do valor calculado pelo modelo.

Além disso, as previsões das temperaturas apresentam uma redução de *offset* maior, e convergência mais rápida no caso de Q igual à I , do que na situação neste momento avaliada. Tal comportamento pode ser confirmado pela avaliação nas raízes dos erros quadráticos médios em cada um dos cenários, conforme exibido na Tabela 9.

Tabela 9: Raiz quadrada do erro quadrático médio, média, desvio padrão e valores de máximo e mínimo de P_PDG , T_PDG , P_TPT e T_TPT para cada valor do parâmetro j estudado quando $Q = jQ'$.

	P_PDG (kgf/cm ²)	T_PDG (°C)	P_TPT (kgf/cm ²)	T_TPT (°C)
$j = 1$				
<i>REQM</i>	1,403	0,055	0,173	0,327
Média	158,201	111,232	35,359	32,785
Desvio Padrão	3,322	0,070	1,502	0,749
Mínimo	148,981	110,575	30,899	31,434
Máximo	174,017	111,338	36,894	34,552
$j = 0,5$				
<i>REQM</i>	1,829	0,100	0,257	0,397
Média	158,241	111,227	35,373	32,842
Desvio Padrão	3,489	0,106	1,512	0,710
Mínimo	149,085	110,082	30,828	31,537
Máximo	179,197	111,338	36,887	34,696
$j = 0,1$				
<i>REQM</i>	3,164	0,279	0,666	0,631
Média	158,951	111,197	35,526	33,181
Desvio Padrão	4,258	0,280	1,679	0,592
Mínimo	149,433	108,300	30,529	32,094
Máximo	186,305	111,382	38,516	34,831
$j = 0,05$				
<i>REQM</i>	5,567	0,429	1,019	0,811
Média	160,685	111,152	35,749	33,402
Desvio Padrão	5,958	0,425	1,915	0,510
Mínimo	149,703	107,590	30,299	32,433
Máximo	187,524	111,422	39,639	34,849
$j = 0,01$				
<i>REQM</i>	15,926	1,162	2,420	1,155
Média	171,686	110,744	37,260	33,754
Desvio Padrão	9,084	1,068	2,436	0,380
Mínimo	156,262	106,143	30,708	32,885
Máximo	189,168	111,485	40,954	34,864

A avaliação dos dados apresentados na Tabela 9 confirma o comportamento observado em relação à filtragem das temperaturas. Nesse caso, observa-se que qualquer aumento nos coeficientes de \mathbf{Q} geram uma previsão por parte do filtro mais tendenciosa à modelagem cada vez mais acurada das medidas, tendendo a partir de certo ponto a menosprezar a capacidade do modelo em realizar as estimativas.

Os resultados referentes ao último cenário avaliado são apresentados na sequência. Nesse caso, j é capaz de ponderar a relação entre os efeitos dos ruídos das medidas, que não são mais fixos, e do processo, conforme a relação apresentada na Equação 4-2.

$$\begin{cases} \mathbf{Q} = j\mathbf{Q}' \\ \mathbf{R} = (1 - j)\mathbf{R}' \end{cases} \quad (4-2)$$

Dessa maneira, quanto maior o valor atribuído ao parâmetro j , maior tende a ser a influência das medidas na filtragem, visto o aumento no valor da covariância do modelo em relação ao valor base, alinhado à redução dos termos da matriz de covariância das medidas. Ao mesmo tempo, quando j se aproxima de zero, maior será a influência da covariância dos ruídos do processo sobre a ação do Filtro, e menor será a influência da covariância dos ruídos das medidas; ou seja, mais o filtro tende a se aproximar dos valores determinados pelo modelo, e maior o tempo de convergência necessário esperado.

Os resultados do EKF da pressão do fundo do poço com base no cenário descrito, para j assumindo os valores de 0,01, 0,05, 0,1 e 0,5 encontram-se na Figura 13:

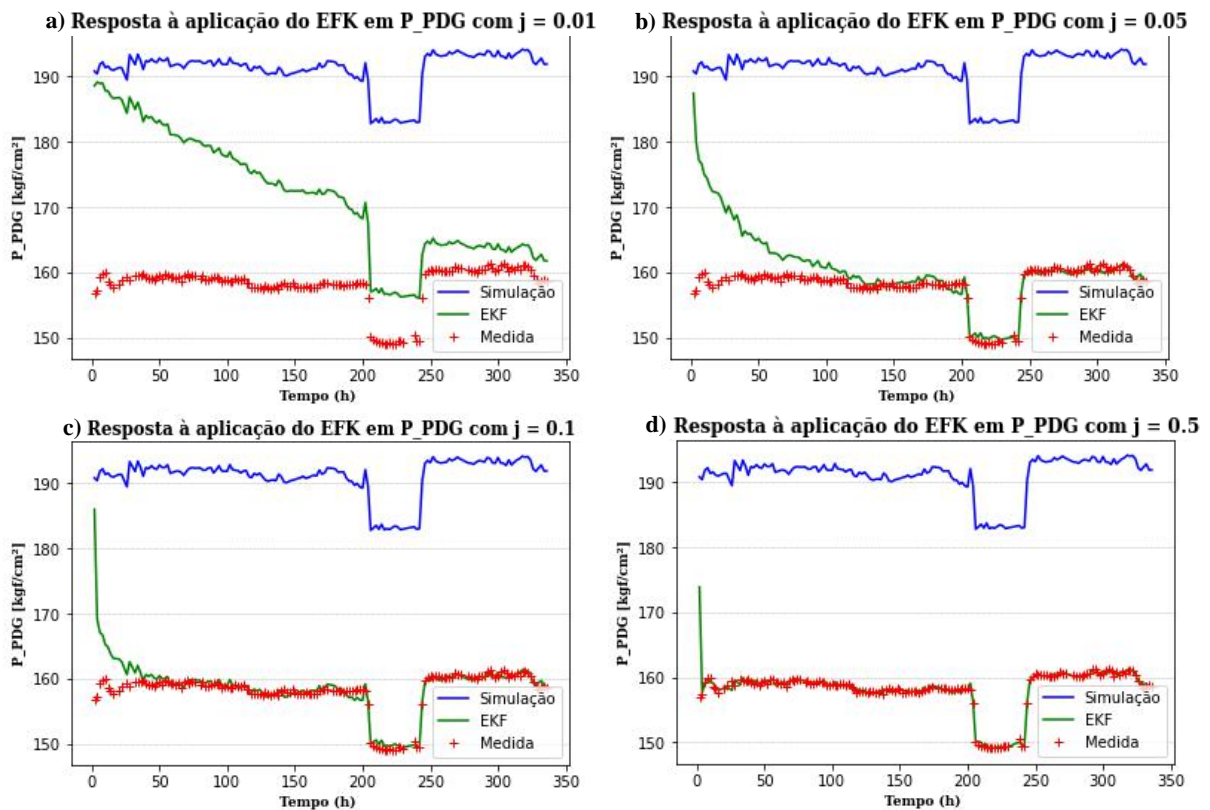


Figura 13: Comparação entre as medidas da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = jQ'$ e $R = (1 - j)R'$. a: caso em que $j = 0,01$; b: caso em que $j = 0,05$; c: caso em que $j = 0,1$; d: caso em que $j = 0,5$.

Nesse cenário observam-se comportamentos bem próximos aos gerados quando a matriz R se mantinha fixa, porém ao aumentar a incerteza sobre as respostas do modelo, e ao reduzir aquelas associadas às medidas, é esperada a tendência de uma convergência mais acelerada, tendo como resposta raízes dos erros quadráticos médios ligeiramente menores ao se avaliar um mesmo valor de j , pois a resposta tende a se aproximar mais rapidamente das medidas. Quando o parâmetro j é igual a 0,5 a resposta deve ser a mesma para o cenário base, pois ambas as matrizes sofrem a mesma influência.

Os valores observados em cada um dos cenários encontram-se explicitados na Tabela 10, a seguir:

Tabela 10: Raiz quadrada do erro quadrático médio, média, desvio padrão e valores de máximo e mínimo de P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} para cada valor do parâmetro j estudado quando $Q = jQ'$ e $R = (1 - j)R'$.

	P_{PDG} (kgf/cm ²)	T_{PDG} (°C)	P_{TPT} (kgf/cm ²)	T_{TPT} (°C)
$j = 0,5$				
<i>REQM</i>	1,391	0,055	0,170	0,327
Média	158,200	111,232	35,359	32,785
Desvio Padrão	3,317	0,069	1,502	0,749
Mínimo	148,981	110,587	30,899	31,434
Máximo	173,857	111,338	36,894	34,536
$j = 0,1$				
<i>REQM</i>	2,923	0,259	0,616	0,608
Média	158,800	111,201	35,503	33,149
Desvio Padrão	4,090	0,261	1,652	0,602
Mínimo	149,393	108,448	30,559	32,046
Máximo	185,995	111,376	38,285	34,825
$j = 0,05$				
<i>REQM</i>	5,280	0,411	0,984	0,797
Média	160,468	111,158	35,725	33,387
Desvio Padrão	5,759	0,408	1,891	0,517
Mínimo	149,678	107,656	30,317	32,412
Máximo	187,431	111,419	39,544	34,847
$j = 0,01$				
<i>REQM</i>	15,832	1,153	2,406	1,154
Média	171,579	110,750	37,243	33,753
Desvio Padrão	9,080	1,060	2,436	0,380
Mínimo	156,157	106,164	30,693	32,884
Máximo	189,124	111,485	40,945	34,864

Todos os cenários avaliados de sintonia da matriz Q do Filtro de Kalman apresentaram boas convergências para coeficientes maiores. Como a utilização do filtro teve como objetivo reduzir o *offset* apresentado pela simulação dos dados a partir do modelo desenvolvido por Guedes (2015), é possível afirmar que sua implementação foi capaz de alcançar o objetivo traçado. O tempo total para simulação das 324 *h* avaliadas foi de aproximadamente 68,5 *min*, configurando a metodologia apresentada como solução vantajosa devido ao seu baixo custo computacional. No caso de sua implementação *on-line*, seria recomendada a sintonização com base na mescla entre a matriz identidade e a matriz formada pelas variâncias do modelo, que prevê uma margem de segurança considerável no caso do ajuste das temperaturas quando os parâmetros são iguais à 1, e apresenta convergência razoável para as pressões, lidando bem com ruídos durante a filtragem.

A escolha da melhor sintonia para apresentação dos resultados neste trabalho deve levar em conta que, para todos os cenários avaliados, se $j > 0,1$, os valores da raiz quadrada do erro quadrático médio obtidos entre as previsões a partir da filtragem e as medidas da planta apresentam boas respostas. A menor redução da raiz quadrada do erro quadrático médio observada dentro desse panorama foi de 3,95 vezes para T_{TPT} , quando se aplica a influência de j apenas sobre a matriz \mathbf{Q} e j é igual a 0,5, confirmando a eficiência da utilização do filtro para os devidos fins.

Considerando que as maiores divergências são apresentadas pela pressão no fundo do poço e a implementação, dentre as apresentadas, que se adequou com mais sucesso foi aquela na qual \mathbf{Q} é igual ao produto da matriz identidade multiplicada pelo vetor das variâncias de cada estado do sistema, esta é considerada a melhor opção de sintonia, dentre as avaliadas, para a predição dos estados. Nesse caso, as variáveis P_{PDG} , T_{PDG} , P_{TPT} e T_{TPT} apresentaram *offset* médio de 0,099 kgf/cm², 0,007 °C, 0,017 kgf/cm² e 0,075 °C, respectivamente, contra 33,019 kgf/cm², 5,718 °C, 5,131 kgf/cm² e 1,471 °C a partir dos cálculos decorrentes da modelagem do sistema apresentada por Guedes (2015), e *offsets* médios relativos de $6,26 \times 10^{-4}$, $6,23 \times 10^{-4}$, $4,81 \times 10^{-4}$ e $2,23 \times 10^{-3}$ contra 0,209, 0,051, 0,145 e 0,045 para os mesmos cenários.

Sendo assim, a aplicação do Filtro de Kalman Estendido sobre o modelo matemático utilizado mostrou-se promissora, tendo apresentado boa adequação ao conjunto de dados utilizado no estudo, sob baixo custo computacional. Tal fato torna possível ainda que se avalie o cenário de aplicação *on-line* da metodologia como forma de substituição de sensores ou mesmo de *back-up* em caso de falhas. Nesse caso, se faz importante o estudo de sua adequação sobre conjuntos de dados apresentando maior flutuação e cenários de instabilidade, buscando-se soluções para a determinação de conjuntos de estimativas iniciais que levem à convergência do modelo matemático sob variações bruscas nas variáveis de entrada e para a determinação das condições de sintonia adequadas.

V. CONCLUSÕES

O trabalho apresentado teve como objetivo principal a aplicação do Filtro de Kalman Estendido, um estimador de estados utilizado em diversos campos da ciência e desenvolvido a partir das sucessivas linearizações do modelo não linear e aplicação do Filtro de Kalman tradicional, sobre o modelo desenvolvido por Guedes (2015) para predição de temperatura e pressão ao longo do comprimento de um poço de produção de óleo e gás. A implementação do filtro foi realizada a partir de um conjunto de dados de pressão e temperatura no fundo e topo do poço, localizados nas porções relativas à 6226,5 m e 3623,8 m, respectivamente, dentro do comprimento total da linha de produção de 7145,5 m.

O conjunto de dados fornecido, a partir do qual foi realizada a implementação do filtro, continha inicialmente 169 pontos, referentes a medições realizadas entre os dias 1 de abril e 15 de abril de 2016, espaçadas em iguais períodos de 2 h. Após pré-processamento dos dados, visando remoção de pontos apresentando grande discrepância em relação ao conjunto total de dados, o total avaliado foi reduzido para 162 pontos; e, por limitações de convergência da aplicação do modelo utilizado, a remoção de mais 3 pontos foi necessária, resultando no total de 159 dados disponíveis para aplicação do filtro.

Os resultados indicaram que a aplicação da filtragem foi capaz de reduzir significativamente o *offset* apresentado pela resolução do modelo utilizado sobre as variáveis medidas no poço, sendo necessários cerca de 68,5 min para a simulação das 324 h avaliadas em cada um dos cenários, mostrando-se, portanto, uma estratégia vantajosa para o acompanhamento do processo, dado seu baixo custo computacional. Ponderou-se como mais importantes para a apresentação de uma maior convergência as variáveis que apresentavam maiores *offsets* relativos aos dados medidos, são elas as identificadas como P_{PDG} e P_{TPT} . Nesse sentido, o resultado mais satisfatório dentre os cenários avaliados foi o de sintonia do filtro considerando \mathbf{Q} e \mathbf{R} diagonais, cujos termos não nulos são dados pelas variâncias relativas à simulação original do modelo e medidas da planta, respectivamente.

Para o melhor cenário de sintonia do filtro identificado durante o estudo, os *offsets* médios relativos calculados foram de $6,26 \times 10^{-4}$, $6,23 \times 10^{-4}$, $4,81 \times 10^{-4}$ e $2,23 \times 10^{-3}$ para a pressão e temperatura no fundo do poço, e pressão e temperatura no topo do poço após aplicação do filtro, contra 0,209, 0,051, 0,145 e 0,045, antes de sua aplicação. A raiz quadrada do erro quadrático médio para cada variável também foi determinado em ambos os casos, tendo apresentado redução de 23,5 vezes para P_{PDG} , 104,4 vezes para T_{PDG} , 29,8 vezes para P_{TPT} e 4,8 vezes para T_{TPT} a partir da aplicação do filtro.

Visando averiguar a eficiência do Filtro de Kalman sobre as respostas ao modelo proposto por Guedes (2015) é almejada, para trabalhos futuros, a implementação da mesma metodologia sobre demais conjuntos de dados; além do estudo da aplicação de metodologias mais sofisticadas de estimação de estados sobre os conjuntos de dados. Dessa maneira, no primeiro caso, seria possível a avaliação do efeito da alteração das características gerais do poço, identificadas como parâmetros do modelo, tanto na determinação dos resultados da simulação prévia, quanto na resposta de velocidade de convergência e melhor cenário de sintonia do Filtro de Kalman Estendido; além do estudo e avaliação da adequação da metodologia em cenários de instabilidade do poço. Enquanto isso, no segundo caso, torna-se possível a validação da melhor estratégia a ser implementada, com base nos resultados obtidos e esforço computacional necessário para previsão dos estados em cada uma delas.

REFERÊNCIAS BIBLIOGRÁFICAS

- AARSNES, U. J. F.; FLÅTTEN, T.; AAMO, O. M. **Review of two-phase flow models for control and estimation.** Annual Reviews in Control, v. 42, p. 50–62, 2016. DOI: 10.1016/j.arcontrol.2016.06.001. Disponível em: <<http://dx.doi.org/10.1016/j.arcontrol.2016.06.001>>. Acesso em: 09 dez. 2021.
- AGU, C. E.; LIE, B. **Smart Sensors for Measuring Fluid Flow using a Venturi Channel.** 55th Conference on Simulation and Modelling (SIMS 55). 2014
- AHRENS, H.; ARGIN, F.; KLINKENBUSCH, L. **Comparison of the Extended Kalman Filter and the Unscented Kalman Filter for Magnetocardiography activation time imaging.** Advances in Radio Science, v. 11, p. 341–346, 2013. DOI: 10.5194/ars-11-341-2013.
- AL-QUTAMI, T. A.; IBRAHIM, R.; ISMAIL, I., *et al.* **Development of soft sensor to estimate multiphase flow rates using neural networks and early stopping.** International Journal on Smart Sensing and Intelligent Systems, v. 10, n. 1, p. 199–222, 2017. DOI: 10.21307/ijssis-2017-209.
- ARCHER, J. S.; WALL, C. G. **Petroleum Engineering - Principles and Practice.** Londres, Graham and Trotman Inc., 1986.
- BACKX, T.; BOSGRA, O.; MARQUARDT, W. **Towards intentional dynamics in supply chain conscious process operations.** AIChE Symposium Series, v. 320, n. 94, p. 5–20, 1998. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.42.159>>. Acesso em: 22 dez. 2021.
- BAGAJEWICZ, M. J.; JIANG, Q. **Gross error modeling and detection in plant linear dynamic reconciliation.** Computers and Chemical Engineering, v. 22, n. 12, p. 1789–1809, 1998. DOI: 10.1016/S0098-1354(98)00248-8.
- BAI, Y.; BAI, Q., **Susbsea Pipelines and Risers - Part III: Flow Assurance.** 1st. ed. New York, Elsevier, 2005. p. 277–316.
- BAI, Y.; WANG, X.; JIN, X. *et al.* **A Neuron-Based Kalman Filter with Nonlinear.** Sensors, v. 20, n. 299, 2020. DOI: doi:10.3390/s20010299.
- BASTIANONI, S.; CAMPBELL, D.; SUSANI, L. *et al.* **The solar transformity of oil and petroleum natural gas.** Ecological Modelling, v. 186, n. 2, p. 212–220, 2005. DOI:

10.1016/j.ecolmodel.2005.01.015.

BEGGS, H. D.; BRILL, J. P. **A Study of Two-Phase Flow in Inclined Pipes**. Journal of Petroleum Technology, v. 255, p. 607–617, 1973.

BIKMUKHAMETOV, T.; JÄSCHKE, J. **First Principles and Machine Learning Virtual Flow Metering: A Literature Review**. Journal of Petroleum Science and Engineering, v. 184, p. 106487, 2020. DOI: 10.1016/j.petrol.2019.106487. Disponível em: <<https://doi.org/10.1016/j.petrol.2019.106487>>. Acesso em 09 dez. 2021.

BRILL, J. P.; MUKHERJEE, H. **Multiphase Flow in Wells**. SPE Monograph Series, 1999.

BROWN, R. G.; HWANG, P. Y. C. **Introduction to Random Signals and Applied Kalman Filtering: with MATLAB Exercises and Solutions**. 3ª ed.: John Wiley & Sons, 1997.

CAPRON, B. **Representações lineares em tempo contínuo**. Rio de Janeiro. out. 2021. Apresentação de Power Point. 23 slides.

CORNELIUSSEN, S.; COUPUT, J.-P.; DAHL, E., *et al.* **Handbook of multiphase flow metering**. Elsevier, 2005. v. 55.

DAUBERT, T. E.; DANNER, R. P. **API Technical Data Book - Petroleum Refining**. 6. ed. Washington, DC, American Petroleum Institute, 1997.

FALCONE, G.; HEWITT, G. F.; ALIMONTI, C. *et al.* **Multiphase Flow Metering: Current Trends and Future Developments**. Proceedings - SPE Annual Technical Conference and Exhibition, p. 1291–1303, 2001. DOI: 10.2118/71474-ms.

FALCONE, G.; HEWITT, G. F.; ALIMONTI, C. **Multiphase Flow Metering: Principles and Applications - Developments in Petroleum Science**. [s.n.], 2009.

FONTE, B. F. **Estudo de Mapas de Regime de Escoamento Gás-Líquido em Dutos Horizontais**. 2010. 91 f. Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2010.

FORTUNA, L.; GRAZIANI, S.; RIZZO, A. *et al.* **Soft Sensors for Monitoring and Control of Industrial Processes**. Springer, [s.n.], 2007.

GARCÍA, A.; ALMEIDA, I.; SINGH, G. *et al.* **An implementation of on-line well virtual metering of oil production**. SPE Intelligent Energy Conference and Exhibition 2010, v. 1, p. 132–140, 2010. DOI: 10.2118/127520-ms.

GESTHUISEN, R.; KLATT, K. U.; ENGELL, S. **Optimization-based state estimation - A comparative study for the batch polycondensation of polyethyleneterephthalate**. 2001 European Control Conference, ECC 2001, n. 2, p. 1062–1067, 2001. DOI: 10.23919/ecc.2001.7076055.

GÓES, M. R. R. T.; GUEDES, T. A. L.; D'AVILA, T. C. *et al.* **Virtual flow metering of oil wells for a pre-salt field**. Journal of Petroleum Science and Engineering, v. 203, n. November 2020, 2021. DOI: 10.1016/j.petrol.2021.108586.

GRAHAM, E. **The future of flow**. Offshore Engineer, v. 40, p. 44–45, 2015.

GRYZLOV, A. N. **Model-based estimation of multi-phase flows in horizontal wells**. [s.n], 2011. v. PhD. Disponível em: <<https://repository.tudelft.nl/islandora/object/uuid:ccd6b7f0-e360-4385-a692-eedbb6e4502d/datastream/OBJ/download>>. Acesso em: 21 dez. 2021.

GUEDES, T.; CURITIBA, C; DORIGO, L. **Utilização de Modelo para Flowlines em Inferências de PDG e TPT: Avaliação dos Resultados Perante a Utilização de Dados de Planta Historiados**. Rio de Janeiro. Out. 2016. Apresentação de Power Point. 34 slides.

GUEDES, T. A. L. **Modelagem do escoamento em linhas de produção offshore com garantia de escoamento**. Tese (Engenharia Química) - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2015.

HABIB, T. M. A. **Simultaneous spacecraft orbit estimation and control based on GPS measurements via extended Kalman filter**. Egyptian Journal of Remote Sensing and Space Science, v. 16, n. 1, p. 11–16, 2013. DOI: 10.1016/j.ejrs.2012.11.002. Disponível em: <<http://dx.doi.org/10.1016/j.ejrs.2012.11.002>>. Acesso em: 17 dez. 2021.

HAMISCH, H. D. **Projeto de um Filtro de Kalman Estendido para Estimação da Localização Geográfica de Pessoas em Ambientes Externos**. Orientador: Daniel Hamisch 2021. 82 f. TCC (Graduação) - Engenharia de Controle e Automação, Centro Tecnológico, Universidade Federal de Santa Catarina, Santa Catarina. 2021. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/224519?show=full>>. Acesso em 16 fev. 2022 .

HASELTINE, E. L.; RAWLINGS, J. B. **Extended Kalman vs moving horizon estimation**. 2005, Hasetine, p. 2451–2460, 2005.

HASSAN, A. **Review of the Global Oil And Gas Industry: A Concise Journey From**

Ancient Time to Modern World. Petroleum Technology Development Journal, v. 3, n. January, p. 20, 2014.

HOLMÅS, K.; LUNDE, G. G.; SETYADI, G. *et al.* **Ormen lange Flow Assurance System (FAS) - Online flow assurance monitoring and advice.** Proceedings of the Annual Offshore Technology Conference, v. 1, p. 234–246, 2013. DOI: 10.4043/24297-ms.

HONG-DE, D.; SHAO-WU, D.; YUAN-CAI, C. *et al.* **Performance Comparison of EKF/UKF/CKF for the Tracking of Ballistic Target.** TELKOMNIKA Indonesian Journal of Electrical Engineering, v. 10, n. 7, p. 1692–1699, 2012. DOI: 10.11591/telkomnika.v10i7.1564.

IDSØ, E. S.; SPERLE, I. L.; AASHEIM, R. *et al.* **Automatic subsea deduction well testing for increased accuracy and reduced test time.** Society of Petroleum Engineers - 30th Abu Dhabi International Petroleum Exhibition and Conference, ADIPEC 2014: Challenges and Opportunities for the Next 30 Years, v. 3, p. 1737–1745, 2014. DOI: 10.2118/171840-ms.

JULIER, S. J.; UHLMANN, J. K.; DURRANT-WHYTE, H. F. **New approach for filtering nonlinear systems.** Proceedings of the American Control Conference, v. 3, p. 1628–1632, 1995. DOI: 10.1109/acc.1995.529783.

JULIER, S. J.; UHLMANN, J. K. **New extension of the Kalman filter to nonlinear systems.** Signal Processing, Sensor Fusion, and Target Recognition VI, v. 3068, p. 182, 1997. DOI: 10.1117/12.280797.

LESKENS, M.; DE KRUIF, B.; BELFROID, S. *et al.* **Downhole multiphase metering in wells by means of soft-sensing.** Society of Petroleum Engineers - Intelligent Energy Conference and Exhibition: Intelligent Energy 2008, v. 1, n. 2007, p. 271–281, 2008. DOI: 10.2118/112046-ms.

LEWIS, J. M.; LAKSHMIVARAHAN, S.; DHALL, S. **Dynamic Data Assimilation: A Least Squares Approach.** [s.n.], 2006. v. 39.

LI, Q.; LI, R.; JI, K. *et al.* **Kalman filter and its application.** Proceedings - 8th International Conference on Intelligent Networks and Intelligent Systems, ICINIS 2015, n. 10, p. 74–77, 2016. DOI: 10.1109/ICINIS.2015.35.

LOPES, L. de M.; PEIXOTO, Z. M. A. **Um Filtro de Kalman Estendido, com matrizes de covariância pré-ajustadas, aplicadas ao controle de velocidade sensorless de motores de indução trifásicos.** Revista Científica Multidisciplinar Núcleo do Conhecimento, p. 109–126,

2020. DOI: 10.32749/nucleodoconhecimento.com.br/engenharia-eletrica/filtro-de-kalman.

MAHFOUZ, S.; MOURAD-CHEHADE, F.; HONEINE, P. *et al.* **Target tracking using machine learning and kalman filter in wireless sensor networks.** IEEE Sensors Journal, v. 14, n. 10, p. 3715–3725, 2014. DOI: 10.1109/JSEN.2014.2332098.

MARSHALL, C.; THOMAS, A. **Maximising economic recovery - A review of well test procedures in the North Sea.** Society of Petroleum Engineers - SPE Offshore Europe Conference and Exhibition, OE 2015, 2015. DOI: 10.2118/175518-ms.

PATEL, P.; ODDEN, H.; DJORIC, B. *et al.* **Model based multiphase metering and production allocation.** Proceedings of the Annual Offshore Technology Conference, v. 4, p. 3336–3344, 2014. DOI: 10.4043/25457-ms.

PERLINGEIRO, C. A. **Engenharia de Processos: Análise, Simulação, Otimização e Síntese de Processos Químicos.** 2^a ed. Blucher, 2005. p. 66. Disponível em <https://issuu.com/editorablucher/docs/issuu_engenharia_processos_isbn9788521203681/1?e=1099747/5186154>, Acesso em 16 fev. 2021.

RAO, C. V.; RAWLINGS, J. B. **Constrained process monitoring: Moving-horizon approach.** AIChE Journal, v. 48, n. 1, p. 97–109, 2002. DOI: 10.1002/aic.690480111.

RAO, C. V.; RAWLINGS, J. B.; MAYNE, D. Q. **Constrained state estimation for nonlinear discrete-time systems: Stability and moving horizon approximations.** IEEE Transactions on Automatic Control, v. 48, n. 2, p. 246–258, 2003. DOI: 10.1109/TAC.2002.808470.

RAWLINGS, J. B.; BAKSHI, B. R. **Particle filtering and moving horizon estimation.** Computers and Chemical Engineering, v. 30, n. 10–12, p. 1529–1541, 2006. DOI: 10.1016/j.compchemeng.2006.05.031.

RAYYAM, M.; ZAZI, M.; BARRADI, Y. **A new metaheuristic unscented Kalman filter for state vector estimation of the induction motor based on Ant Lion optimizer.** COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering, v. 37, n. 3, p. 1054–1068, 2018. DOI: 10.1108/COMPEL-06-2017-0239.

RIAZI, M. R. **Characterization and Properties of Petroleum Fractions.** 1. ed. West Conshohocken, American Society for Testing and Materials, 2005.

SALAU, N. P. G. **Abordagem Sistemática para Construção e Sintonia de Estimadores de Estados Não-Lineares**. 2009. 188 f. Tese (Engenharia Química) - Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, 2009.

SANTOSH, D. H.; MOHAN, P. G. K. **Multiple objects tracking using Extended Kalman Filter, GMM and Mean Shift Algorithm-A comparative study**. Proceedings of 2014 IEEE International Conference on Advanced Communication, Control and Computing Technologies, ICACCCT 2014, n. 978, p. 1484–1488, 2015. DOI: 10.1109/ICACCCT.2014.7019350.

SANTOS-LEÓN, J. C., ORIVE, R., ACOSTA, D., et al. **The Cubature Kalman Filter revisited**. Automatica, v. 127, p. 109541, 2021. DOI: 10.1016/j.automatica.2021.109541. Disponível em: <https://doi.org/10.1016/j.automatica.2021.109541>. Acesso em: 23 fev. 2022.

SÄRKKÄ, S. **Lecture 5: Unscented Kalman filter and Particle Filtering**. 21 abr. 2009. Apresentação de Power Point. 37 slides. Disponível em: <https://users.aalto.fi/~ssarkka/course_k2009/slides_5.pdf>. Acesso em: 17 fev. 2022.

SCHURK, F. J.; DESHPANDE, P. B.; LEFFEW, K. W. *et al.* **Control of polymerization reactors**. Control of Polymerization Reactors, v. 19, n. 15, p. 1–355, 2017. DOI: 10.1201/9781315140322. Disponível em: <[http://dx.doi.org/10.1016/S1474-6670\(17\)59395-7](http://dx.doi.org/10.1016/S1474-6670(17)59395-7)>. Acesso em: 12 fev. 2022.

STEVENS, W. F.; THODOS, G. **Estimation of Enthalpies: Multicomponent Hydrocarbon Mixtures at Their Saturated Vapor and Liquid States**. AIChE Journal, v. 9, p. 293–296, 1963.

TEIXEIRA, R. G. D. **Abordagem Algébrico-Diferencial na Simulação Unidimensional do Escoamento Bifásico em Tubos para Processo de Refino**. 2013. 216 f. Tese (Engenharia Química) - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Univerisdade Federal do Rio de Janeiro, Rio de Janeiro. 2013.

THOME, J. R. **Engineering Data Book**. 3th. ed. Lausanne, Suíça, Wolverine Tubes, Inc., 2010.

TONEL, G.; SALAU; N. P. G., TRIERWEILER, J. O. *et al.* **Comprehensive evaluation of EKF , CEKF , and Moving Horizon estimators for on-line processes applications**. 18° European Symposium on Computer Aided Process Engineering, 2008.

TOSKEY, E. **OTC 2331 Improvements to Deepwater Subsea Measurements RPS SEA Pro Evaluation of Flow Modelling**. Offshore Technology Conference, 2012.

URSINI, F.; ROSSI, R.; CASTELNUOVO, L. *et al.* **The benefits of virtual meter applications on production monitoring and reservoir management**. Society of Petroleum Engineers - SPE Reservoir Characterisation and Simulation Conference and Exhibition 2019, RCSC 2019, 2019. DOI: 10.2118/196654-ms.

VALAPPIL, J.; GEORGAKIS, C. **Systematic estimation of state noise statistics for extended Kalman filters**. AIChE Journal, v. 46, n. 2, p. 292–308, 2000. DOI: 10.1002/aic.690460209.

WANG, Y.; DING, F.; WU, M. **Recursive parameter estimation algorithm for multivariate output-error systems**. Journal of the Franklin Institute, v. 355, n. 12, p. 5163–5181, 2018. DOI: 10.1016/j.jfranklin.2018.04.013.

WHITSON, C. H.; BRULE, M. R. **Phase Behavior**. Richardson, Texas, Henry L. Doherty Memorial Fund of AIME, SPE, 2000.

YANG, Y.; LI, J. **Comparison of the extended and unscented Kalman filters for satellite motion states estimation**. Proceedings of 2012 International Conference on Measurement, Information and Control, MIC 2012, v. 1, n. Mic, p. 440–444, 2012. DOI: 10.1109/MIC.2012.6273337.

YERGIN, D. **The Price: The Epic Quest for Oil, Money and Power**. New York, [s.n.], 2008.

YIN, Z.; LI, G.; ZHANG, Y. *et al.* **A Speed and Flux Observer of Induction Motor Based on Extended Kalman Filter and Markov Chain**. IEEE Transactions on Power Electronics, v. 32, n. 9, p. 7096–7117, 2017. DOI: 10.1109/TPEL.2016.2623806.

ZERDALI, E.; BARUT, M. **The Comparisons of Optimized Extended Kalman Filters for Speed-Sensorless Control of Induction Motors**. IEEE Transactions on Industrial Electronics, v. 64, n. 6, p. 4340–4351, 2017. DOI: 10.1109/TIE.2017.2674579.

APÊNDICE I

Perfis dos estados simulados com $Q = 0,01Q'$ e $Q' = I$.




Figura 14: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e $Q' = I$.

Resposta à aplicação do EFK em T_TPT com $j = 0.01$




Figura 15: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e $Q' = I$.

Resposta à aplicação do EFK em P_TPT com $j = 0.01$




Figura 16: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e $Q' = I$.

Perfis dos estados simulados com $Q = 0,05Q'$ e $Q' = I$.




Figura 17: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e $Q' = I$.

Resposta à aplicação do EFK em T_TPT com $j = 0.05$

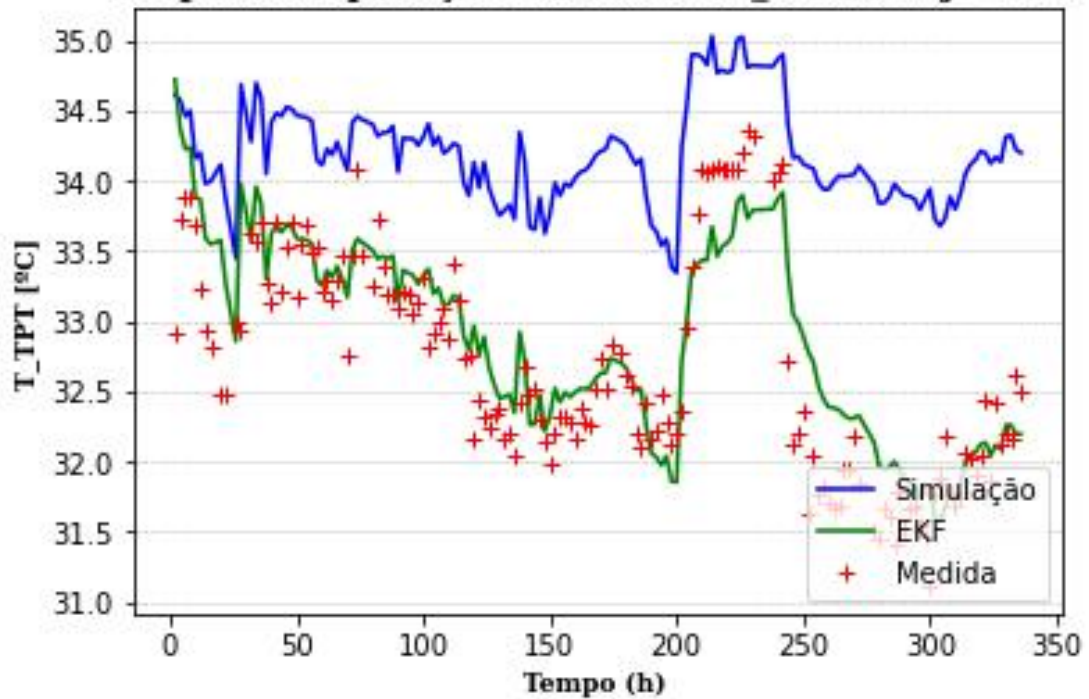


Figura 18: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e $Q' = I$.

Resposta à aplicação do EFK em P_TPT com $j = 0.05$

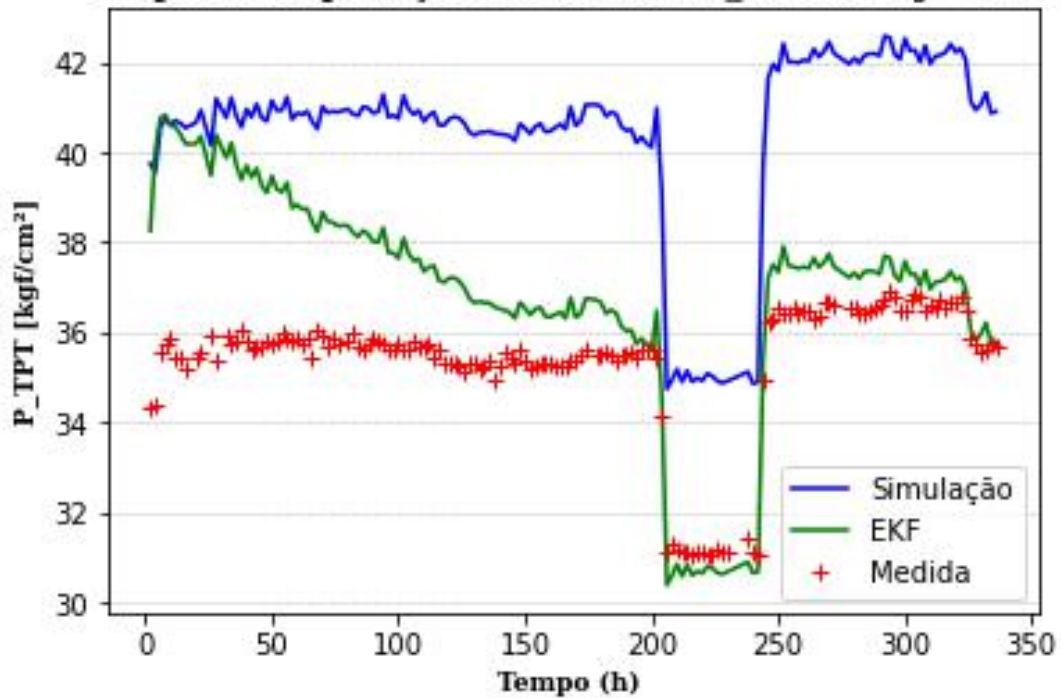


Figura 19: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e $Q' = I$.

Perfis dos estados simulados com $Q = 0,1Q'$ e $Q' = I$.




Figura 20: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e $Q' = I$.

Resposta à aplicação do EFK em T_TPT com $j = 0.1$




Figura 21: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e $Q' = I$.

Resposta à aplicação do EFK em P_TPT com $j = 0.1$




Figura 22: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e $Q' = I$.

Perfis dos estados simulados com $Q = 0,5Q'$ e $Q' = I$.




Figura 23: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e $Q' = I$.

Resposta à aplicação do EFK em T_TPT com $j = 0.5$




Figura 24: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e $Q' = I$.

Resposta à aplicação do EFK em P_TPT com $j = 0.5$




Figura 25: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e $Q' = I$.

APÊNDICE II

Perfis dos estados simulados com $Q = 0,01Q'$ e Q' igual às variâncias das variáveis simuladas.




Figura 26: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e Q' é igual às variâncias.

Resposta à aplicação do EFK em T_TPT com $j = 0.01$




Figura 27: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e Q' é igual às variâncias.

Resposta à aplicação do EFK em P_TPT com $j = 0.01$




Figura 28: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$ e Q' é igual às variâncias.

Perfis dos estados simulados com $Q = 0,05Q'$ e Q' igual às variâncias das variáveis simuladas.




Figura 29: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e Q' é igual às variâncias.




Figura 30: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e Q' é igual às variâncias.




Figura 31: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$ e Q' é igual às variâncias.

Perfis dos estados simulados com $Q = 0,1Q'$ e Q' igual às variâncias das variáveis simuladas.

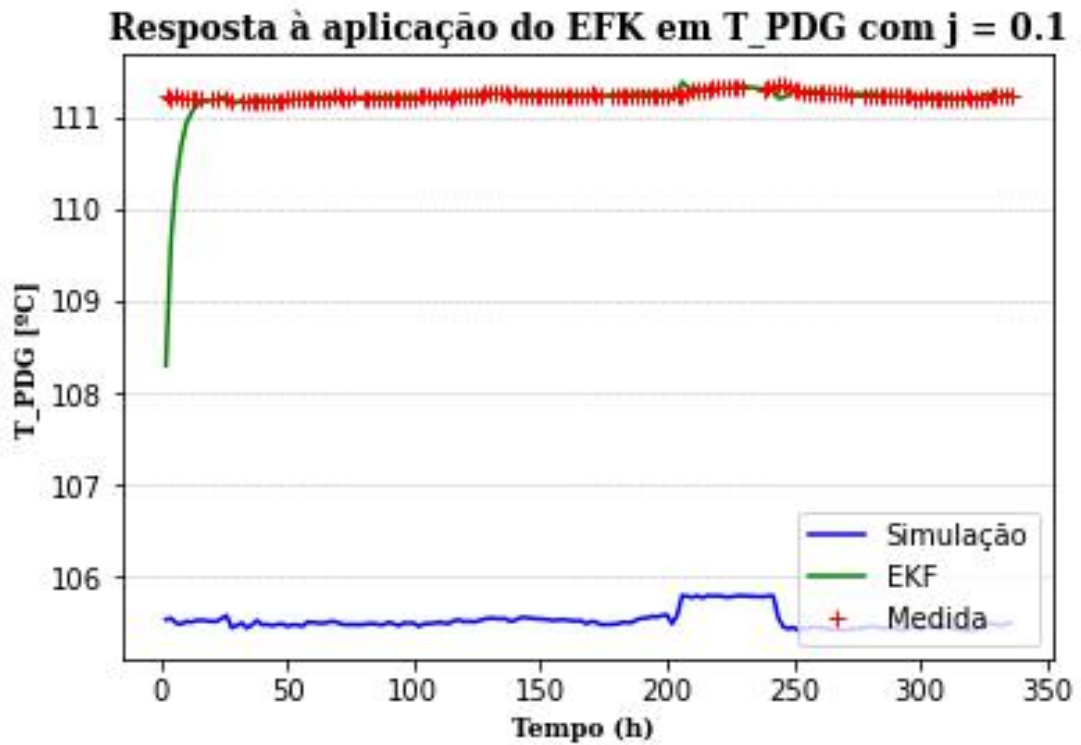


Figura 32: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e Q' é igual às variâncias.




Figura 33: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e Q' é igual às variâncias.




Figura 34: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$ e Q' é igual às variâncias.

Perfis dos estados simulados com $Q = 0,5Q'$ e Q' igual às variâncias das variáveis simuladas.




Figura 35: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e Q' é igual às variâncias.




Figura 36: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e Q' é igual às variâncias.




Figura 37: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$ e Q' é igual às variâncias.

APÊNDICE III

Perfis dos estados simulados com $Q = 0,01Q'$ e Q' igual às variâncias das variáveis simuladas e $R = 0,99R'$.




Figura 38: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$, Q' é igual às variâncias e $R = 0,99R'$.

Resposta à aplicação do EFK em T_TPT com $j = 0.01$




Figura 39: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$, Q' é igual às variâncias e $R = 0,99R'$.

Resposta à aplicação do EFK em P_TPT com $j = 0.01$




Figura 40: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,01Q'$, Q' é igual às variâncias e $R = 0,99R'$.

Perfis dos estados simulados com $Q = 0,05Q'$ e Q' igual às variâncias das variáveis simuladas e $R = 0,95R'$.




Figura 41: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$, Q' é igual às variâncias e $R = 0,95R'$.

Resposta à aplicação do EFK em T_TPT com $j = 0.05$




Figura 42: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$, Q' é igual às variâncias e $R = 0,95R'$.

Resposta à aplicação do EFK em P_TPT com $j = 0.05$




Figura 43: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,05Q'$, Q' é igual às variâncias e $R = 0,95R'$.

Perfis dos estados simulados com $Q = 0,1Q'$ e Q' igual às variâncias das variáveis simuladas e $R = 0,9R'$.




Figura 44: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$, Q' é igual às variâncias e $R = 0,9R'$.

Resposta à aplicação do EFK em T_TPT com $j = 0.1$




Figura 45: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$, Q' é igual às variâncias e $R = 0,9R'$.

Resposta à aplicação do EFK em P_TPT com $j = 0.1$




Figura 46: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,1Q'$, Q' é igual às variâncias e $R = 0,9R'$.

Perfis dos estados simulados com $Q = 0,5Q'$ e Q' igual às variâncias das variáveis simuladas e $R = 0,5R'$.




Figura 47: Comparação entre as medidas de temperatura de fundo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$, Q' é igual às variâncias e $R = 0,5R'$.

Resposta à aplicação do EFK em T_TPT com $j = 0.5$




Figura 48: Comparação entre as medidas de temperatura de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$, Q' é igual às variâncias e $R = 0,5R'$.

Resposta à aplicação do EFK em P_TPT com $j = 0.5$




Figura 49: Comparação entre as medidas de pressão de topo de poço da planta, resposta do modelo e aplicação do Filtro de Kalman Estendido para o caso em que $Q = 0,5Q'$, Q' é igual às variâncias e $R = 0,5R'$.