



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS

WILLIAM CHALUB CRUZ

**AJUSTE DE HISTÓRICO POR CICLOS SOB
DIFERENTES ABORDAGENS PARA
ATUALIZAR AS INCERTEZAS DOS
ATRIBUTOS DE RESERVATÓRIOS**

CAMPINAS

2018

WILLIAM CHALUB CRUZ

**AJUSTE DE HISTÓRICO POR CICLOS SOB
DIFERENTES ABORDAGENS PARA
ATUALIZAR AS INCERTEZAS DOS
ATRIBUTOS DE RESERVATÓRIOS**

Dissertação de Mestrado apresentada à Faculdade de Engenharia Mecânica e Instituto de Geociências da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestre em Ciências e Engenharia de Petróleo, na área de Reservatórios e Gestão.

Orientador: Pesq. Dr. Célio Maschio

Coorientador: Prof. Dr. Denis José Schiozer

Este exemplar corresponde à versão final da Dissertação defendida pelo aluno William Chalub Cruz e orientado pelo Pesq. Dr. Célio Maschio.



Assinatura do Orientador

CAMPINAS

2018

Agência(s) de fomento e nº(s) de processo(s): CAPES, 33003017

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Luciana Pietrosanto Milla - CRB 8/8129

C889a Cruz, William Chalub, 1987-
Ajuste de Histórico por ciclos sob diferentes abordagens para atualizar as incertezas dos atributos de reservatórios / William Chalub Cruz. – Campinas, SP : [s.n.], 2018.

Orientador: Célio Maschio.
Coorientador: Denis José Schiozer.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Engenharia de petróleo. 2. Reservatórios (Simulação). 3. Calibração. 4. Kalman, Filtragem de. 5. Assimilação contínua de dados. I. Maschio, Célio. II. Schiozer, Denis José, 1963-. III. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: History matching by cycles under different approaches to update uncertainties of reservoir attributes **Palavras-chave em inglês:**

Oil engineering

Reservoirs (Simulation)

Calibration

Kalman, Filtration of

Continuous assimilation of data

Área de concentração: Reservatórios e Gestão

Titulação: Mestre em Ciências e Engenharia de Petróleo

Banca examinadora:

Célio Maschio [Orientador]

Guilherme Daniel Avansi

André Carlos Bertolini

Data de defesa: 30-07-2018

Programa de Pós-Graduação: Ciências e Engenharia de Petróleo

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS

DISSERTAÇÃO DE MESTRADO ACADÊMICO

**AJUSTE DE HISTÓRICO POR CICLOS SOB
DIFERENTES ABORDAGENS PARA
ATUALIZAR AS INCERTEZAS DOS
ATRIBUTOS DE RESERVATÓRIOS**

Autor: William Chalub Cruz

Orientador: Pesq. Dr. Célio Maschio

Coorientador: Prof. Dr. Denis José Schiozer

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:

Pesq. Dr. Célio Maschio, Presidente
DE / FEM / UNICAMP

Pesq. Dr. Guilherme Daniel Avansi
DE / FEM / UNICAMP

Dr. André Carlos Bertolini
SCHLUMBERGER/ RJ

A ata dessa defesa com as respectivas assinaturas dos membros encontra-se no processo de vida acadêmica do aluno.

Campinas, 30 de julho de 2018.

DEDICATÓRIA

Dedico este trabalho aos meus pais e irmãos que sempre estiveram ao meu lado e me incentivaram a fazer o mestrado.

AGRADECIMENTOS

Agradeço aos meus orientadores, Pesq. Dr. Célio Maschio e Prof. Dr. Denis José Schiozer pela paciência, oportunidade, profissionalismo e orientação para elaboração deste trabalho.

A todos os funcionários e professores do Departamento de Engenharia de Petróleo (DEP), CEPETRO e UNISIM pela ajuda direta ou indireta para a elaboração deste trabalho.

Aos colegas de mestrado e doutorado por todo apoio, companheirismo e troca de conhecimentos.

Ao Dr. Alexandre A. Emerick (da Petrobras) por fornecer a ferramenta EHM ao UNISIM.

Aos meus pais e irmãos que não mediram esforços, apoio e incentivo durante toda esta fase.

À minha namorada Maristela por toda a ajuda, paciência e companheirismo nesta reta final.

E à CAPES pelo apoio financeiro proporcionado para meus estudos.

RESUMO

Geralmente, a pouca quantidade de informações acerca do reservatório pode acarretar a geração de modelos que não representam de forma precisa o comportamento do reservatório real. Uma maneira de corrigir este problema é a incorporação de dados dinâmicos de produção (dados observados) em um processo denominado ajuste de histórico (AH), fundamental para aumentar a confiabilidade das previsões de produção e melhorar o processo decisório. O processo de AH é um problema inverso de múltiplas soluções, em que se conhece a resposta, mas não os atributos corretos que a reproduzem. Por ser um problema mal posto, diferentes soluções podem gerar bons ajustes com previsões da produção distintas, sendo essencial encontrar o máximo de soluções possíveis para aumentar a confiabilidade nas previsões. Este processo é aplicado à medida que novos dados (ciclos) se encontrem disponíveis. Ao realizar o ajuste de histórico por ciclos (AHC), os modelos são atualizados em cada ciclo para aumentar o conhecimento acerca do reservatório e apoiar as tomadas de decisões. Inúmeros métodos podem ser empregados para realizar o AHC e dentre eles há o Conjunto Suavizado com Múltiplas Assimilações de Dados (*Ensemble Smoother with Multiple Data Assimilation* – ES-MDA) que possui a capacidade de lidar com uma grande quantidade de atributos incertos e gerar múltiplos modelos ajustados.

Este trabalho propõe testar o método ES-MDA com localização em um processo de AHC sob diferentes abordagens para atualizar as incertezas dos atributos entre os ciclos. O principal propósito é avaliar a influência da quantidade de dados observados na qualidade do ajuste e da previsão da produção.

Os resultados mostraram que ao utilizar os atributos a priori (original do modelo) como entrada do ciclo seguinte, a maior quantidade de dados observados dificultou o ajuste em alguns ciclos e conseqüentemente resultou em divergência da resposta real na previsão da produção. No entanto, ao utilizar os atributos a posteriori de um determinado ciclo como entrada no ciclo seguinte, o ajuste dos dados melhorou consideravelmente e também a previsão da produção ao longo dos ciclos. Sendo que, a maior quantidade de dados observados contribuiu diretamente para o aumento da qualidade do ajuste dos dados, principalmente para a vazão de água.

Palavras-Chave: Ajuste de histórico por ciclos; Conjunto suavizado com múltiplas assimilações de dados; Gerenciamento de reservatórios em malha fechada.

ABSTRACT

Usually, the limited reservoir data available is able to generate models which, most part of the time, do not reproduce accurately the behavior of the real reservoir. One way to overcome this problem is to incorporate dynamic data (observed data) in a process called history matching (HM), essential to generate good production forecast and to improve the decision analysis process. The HM process is an inverse problem of multiple solutions, in which the answer is known, but correct attributes that reproduce the answer are unknown. Another important factor is that different solutions can generate good matches with different production forecasts, and it is essential to find as many solutions as possible to increase reliability in forecasting. This process is applied as new data (cycles) becomes available. When applying history matching by cycles (HMC), reservoir simulation models are updated in each cycle to support decision analysis. Several methodologies can be used to perform the HMC. Among the methodologies, there is the Ensemble Smoother with Multiple Data Assimilations (ES-MDA), which has the ability to handle a large number of attributes and generate multiple adjusted models.

The aim of this study is to test the ES-MDA method with localization in a HMC workflow under different approaches to update the uncertainties of the attributes between the cycles. The main purpose is to evaluate the influence of the amount of observed data on the quality of the HM and the production forecast.

The results showed that using the prior attributes (original model) as input to the next cycles, the larger amount of observed data can hinder the quality of the HM in some cycles, and consequently result in a divergence of the real response in the production forecast. However, by using the posteriori attributes of a given cycle as input in the next cycle, the quality of the data matches has improved considerably, as well as, the production forecast over the cycles. As a result, the greater amount of observed data contributed directly to the increase the quality of the data matches, mainly for water rate.

Key Word: History matching by cycles; Ensemble Smoother with Multiple Data Assimilations; Closed-loop reservoir management.

LISTA DE ILUSTRAÇÕES

Figura 2.1: Processo de análise de decisão baseado em modelos por malha fechada (traduzido de Schiozer <i>et al.</i> , 2015)	23
Figura 2.2: Exemplo de ajuste de histórico com múltiplas soluções.....	25
Figura 2.3: Exemplos de distribuições probabilísticas (adaptado de Silva, 2011).....	27
Figura 2.4: Exemplo do ajuste de histórico em tempo real.	29
Figura 2.5: Representação da região de localização definida por uma elipse (Emerick e Reynolds, 2011).....	35
Figura 3.1: Fluxograma do processo de ajuste de histórico por ciclos sob diferentes abordagens.	36
Figura 3.2: Exemplo de distribuição a priori (antes do ajuste) e posteriori (após o ajuste).	37
Figura 3.3: Definição dos atributos escalares nas diferentes abordagens.....	38
Figura 3.4: Exemplo da aplicação da nomenclatura para a Abordagem A ao longo dos ciclos, a priori (antes do ajuste) e a posteriori (após o ajuste).....	40
Figura 4.1: Estratégia de produção do modelo UNISIM-I-M, produtores (a) e injetores (b). .	43
Figura 4.2: Definição da elipse (região de influência) em torno do poço PROD009.....	46
Figura 5.1: Filtragem de modelos para o Total das abordagens A, B e C com base no AQNS : (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.	54
Figura 5.2: Filtragem de modelos para a q_w das abordagens A, B e C com base no AQNS : (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.	55
Figura 5.3: AQNS de q_w dos produtores da Abordagem A: a priori (a) e a posteriori (b).	57
Figura 5.4: Curva de produção de água do poço produtor PROD005 mostrando o ajuste ao longo dos ciclos da abordagem A: (a) (A1)pr1; (b) (A1)pt1; (c) (A2)pr2; (d) (A2)pt2; (e) (A3)pr3; (f) (A3)pt3; (g) (A4)pr4; (h) (A4)pt4; (i) (A5)pr5; (j) (A5)pt5; (k) (A6)pr6 e (l) (A6)pt6.	58
Figura 5.5: AQNS de q_w dos produtores da Abordagem B: a priori (a) e a posteriori (b).	59
Figura 5.6: Curva de produção de água do poço produtor PROD005 mostrando o ajuste ao longo dos ciclos da abordagem B: (a) (A1)pr1; (b) (A1)pt1; (c) (B2)pr2; (d) (B2)pt2; (e) (B3)pr3; (f) (B3)pt3; (g) (B4)pr4; (h) (B4)pt4; (i) (B5)pr5; (j) (B5)pt5; (k) (B6)pr6 e (l) (B6)pt6.	60
Figura 5.7: AQNS de q_w dos produtores da Abordagem C: a priori (a) e a posteriori (b).	61

Figura 5.8: Curva de produção de água do poço produtor PROD005 (histórico) da abordagem B: (a) (A1)pr1; (b) (A1)pt1; (c) (C2)pr2; (d) (C2)pt2; (e) (C3)pr3; (f) (C3)pt3; (g) (C4)pr4; (h) (C4)pt4; (i) (C5)pr5; (j) (C5)pt5; (k) (C6)pr6 e (l) (C6)pt6.	62
Figura 5.9: Desvio padrão normalizado dos atributos escalares da Abordagem A.	64
Figura 5.10: Desvio padrão normalizado dos atributos escalares da Abordagem B.	64
Figura 5.11: Desvio padrão normalizado dos atributos escalares da Abordagem C.	64
Figura 5.12: Exemplo do truncamento realizado pelo método no DWOC.	65
Figura 5.13: Histograma de k_{wiro} das abordagens A, B e C.	68
Figura 5.14: Histograma de P_{krw} das abordagens A, B e C.	69
Figura 5.15: Histograma de DWOC das abordagens A, B e C.	70
Figura 5.16: Desvio padrão da distribuição do $\ln(kz)$ para alguns ciclos das abordagens A, B e C.	71
Figura 5.17: Média da distribuição do $\ln(kz)$	73
Figura 5.18: Curva de probabilidade acumulada para todos os modelos e modelos filtrados das abordagens A, B e C: (a) Abordagem A: N_p – sem filtro; (b) Abordagem A: N_p – com filtro; (c): Abordagem B: N_p – sem filtro; (d) Abordagem B: N_p – com filtro; (e) Abordagem C: N_p – sem filtro; e (f) Abordagem C: N_p – com filtro.	76
Figura 5.19: Previsão da produção: (a) N_p - (A3)pt3; (b) N_p - (A6)pt6; (c) N_p - (B3)pt3; (d) N_p - (B6)pt6.1; (e) N_p - (C3)pt3; (f) N_p - (C6)pt6.	77
Figura 5.20: Curva de probabilidade acumulada para todos os modelos e modelos filtrados das abordagens A, B e C: (a) Abordagem A: W_p – sem filtro; (b) Abordagem A: W_p – com filtro; (c): Abordagem B: W_p – sem filtro; (d) Abordagem B: W_p – com filtro; (e) Abordagem C: W_p – sem filtro; e (f) Abordagem C: W_p – com filtro.	79
Figura 5.21: Previsão da produção: (a) W_p - (A3)pt3; (b) W_p - (A6)pt6; (c) W_p - (B3)pt3; (d) W_p - (B6)pt6.1; (e) W_p - (C3)pt3; (f) W_p - (C6)pt6.	80

LISTA DE TABELAS

Tabela 4.1: Intervalos de tempo de histórico dos ciclos sob diferentes abordagens.	43
Tabela 4.2: Parametrização original das incertezas espaciais e escalares.	45
Tabela 4.3: Parâmetros utilizados para o cálculo do AQNS.	47
Tabela 4.4: Condições operacionais dos poços na etapa de previsão da produção.	48
Tabela 5.1: Porcentagens de modelos filtrados em todos os ciclos nas abordagens A, B e C.	52
Tabela 5.2: Média das incertezas escalares das abordagens A, B e C.	66
Tabela 5.3: Porcentagem dos modelos filtrados para a etapa de previsão da produção.	74

LISTA DE ABREVIATURAS E SIGLAS

AH	Ajuste de Histórico
AHC	Ajuste de Histórico por Ciclos
AHDD	Ajuste de Histórico por Divisão de Dados
AHTR	Ajuste de Histórico em Tempo Real
CLRM	Gerenciamento de Reservatórios em Malha Fechada
EHM	<i>Ensemble History Matching</i>
EnKF	Filtro de Kalman por Conjunto
ES	Conjunto Suavizado
ES-MDA	Conjunto Suavizado com Múltiplas Assimilações de Dados
FK	Filtro de Kalman
FO	Função Objetivo
VPL	Valor Presente Líquido

LISTA DE SÍMBOLOS

A	Afastamento simples
AQA	Afastamento quadrático aceitável
AQNS	Afastamento quadrático normalizado com sinal
AQS	Afastamento quadrático com sinal
BHP	Pressão de fundo do poço
C	Constante
C_D	Matriz de covariância dos erros de medição
C_{DD}	Matriz de autocovariância dos dados simulados
CPOR	Compressibilidade da rocha
C_{MD}	Matriz de covariância cruzada entre os parâmetros e dados observados
d_{obs}	Dados observados
d_{sim}	Dados simulados
DWOC	Contato óleo-água
h	Distância euclidiana
h_x	Distância Euclidiana na direção x
$h_{x'}$	Distância Euclidiana na direção x'
h_y	Distância Euclidiana na direção y
$h_{y'}$	Distância Euclidiana na direção y'
j	Número do modelo
K	Matriz de ganho de Kalman
k_{rw}	Permeabilidade relativa da água
k_{rwiro}	Máxima permeabilidade relativa da água
k_x	Permeabilidade horizontal na direção x
k_y	Permeabilidade horizontal na direção y
k_z	Permeabilidade vertical

L	Distância crítica
L_x	Distância crítica da elipse na direção x
L_y	Distância crítica da elipse na direção y
m	Parâmetros incertos do modelo
MOD	Multiplicador da k_z
N	Número de ciclos
N_{obs}	Número de dados observados
N_e	Número de modelos no conjunto
N_i	Número de iterações
N_p	Produção acumulada de óleo
pdf	Função densidade de probabilidade
P_{krw}	Expoente de saturação
q_l	Vazão de líquido
q_o	Vazão de óleo
q_w	Vazão de água
q_{wi}	Vazão de água injetada
S_{orw}	Saturação de óleo residual
S_w	Saturação de água
S_{wcrit}	Saturação de água crítica
Tol	Tolerância
W_p	Produção acumulada de água
α	Coefficiente de inflação
θ	Ângulo de rotação da elipse
ρ	Matriz de correlação

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Ajuste de Histórico ao Longo do Tempo.....	18
1.2	Motivação	20
1.3	Objetivos.....	21
1.4	Organização da Dissertação.....	21
2	FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA	22
2.1	Análise de Decisão baseada em Modelos por Malha Fechada	22
2.2	Ajuste de Histórico	23
2.2.1	Função Objetivo.....	25
2.2.2	Integração entre o Ajuste de Histórico e Análise de Incertezas	27
2.3	Ajuste de Histórico ao Longo do Tempo.....	28
2.3.1	Ajuste de Histórico em Tempo Real.....	28
2.3.2	Ajuste de Histórico por Ciclos.....	30
2.3.3	Ajuste de Histórico por Divisão de Dados	31
2.4	Filtro de Kalman e suas derivações	32
2.5	ES-MDA com Localização.....	32
3	METODOLOGIA.....	36
3.1	Etapa 1: Definição da Abordagem.....	36
3.2	Etapa 2: Incluir Dados Observados	38
3.3	Etapa 3: ES-MDA.....	38
3.3.1	Aplicação do ES-MDA.....	39
3.3.2	Análise da qualidade do ajuste	39
3.3.3	Análise das incertezas.....	40
3.4	Etapa 4: Filtro	40

3.5	Etapa 5: Previsão da Produção	40
3.6	Etapa 6: Novos Dados Observados?	41
4	APLICAÇÃO	42
4.1	UNISIM-I-M.....	42
4.2	Incluir Dados Observados.....	43
4.3	ES-MDA	44
4.3.1	Aplicação do ES-MDA.....	44
4.3.2	Análise da qualidade do ajuste	47
4.3.3	Análise das incertezas	47
4.4	Previsão da Produção.....	48
5	RESULTADOS E DISCUSSÕES	49
5.1	Análise do ajuste.....	49
5.2	Análise das incertezas	63
5.3	Previsão da Produção.....	73
6	CONCLUSÕES.....	81
6.1	Recomendações para trabalhos futuros.....	82
	REFERÊNCIAS	83
	APÊNDICE A – GRÁFICOS DE FILTRAGEM DE MODELOS	87
	APÊNDICE B – GRÁFICOS DE AQNS.....	91

1 INTRODUÇÃO

O processo de análise de decisão baseado em modelos por malha fechada (*Closed Loop Reservoir Managment – CLRM*) engloba as principais etapas de um estudo de reservatório, tais como a geração de múltiplas realizações e múltiplos modelos de simulação, ajuste de histórico (assimilação de dados dinâmicos) e otimização da produção (Schiozer *et al.*, 2015). A aplicação dessas etapas é fundamental para estimar os riscos envolvidos devido à presença de incertezas nas propriedades de rocha e fluido, modelo econômico e condições operacionais e assim minimizar e/ou maximizar algum indicador (geralmente a produção de água, a produção de óleo ou o valor presente líquido – VPL) e melhorar o processo decisório.

Para aplicar o CLRM é imprescindível ter um conjunto de modelos confiável que consiga reproduzir de modo satisfatório os dados observados (reservatório real). No entanto, mesmo com técnicas modernas de caracterização de reservatórios é difícil quantificar de modo preciso os principais atributos que caracterizam o reservatório, como porosidade, permeabilidade e contato óleo-água, sendo considerado um fator crítico para o processo de construção de modelos de simulação confiáveis (Avansi, 2014).

Portanto, o processo de construção dos modelos não é tão simples devido à dificuldade em se obter informações acerca dos atributos do reservatório, sendo considerados incertos, pois a maior parte das informações é estimada, correlacionada ou não obtida, devido ao elevado custo da aquisição de dados (Costa, 2012). Essa presença de incertezas pode ocasionar a geração de modelos que não representam de forma precisa o comportamento do reservatório real, gerando riscos nas decisões. Logo, se torna necessário realizar um procedimento conhecido na literatura como ajuste de histórico (AH) para gerar modelos mais representativos.

Schiozer *et al.* (2015) desenvolveram uma metodologia baseada em 12 etapas para o CLRM, na qual aplica-se a assimilação de dados para redução de incertezas (AH) nas etapas 3 a 5, denominadas de Calibração do Modelo, Geração de Cenários e Redução de Cenários, respectivamente. Portanto, primeiramente realiza-se uma correção inicial para eliminar dados espúrios e inconsistências entre o modelo base e os dados dinâmicos de produção (Etapa 3). Após esta correção, é realizada a geração de todos os cenários possíveis respeitando a parametrização decorrente do processo de caracterização sob incertezas (Etapa 4), para posterior aplicação da Etapa 5.

A Etapa 5 (foco deste trabalho) é baseada na redução dos cenários gerados na etapa anterior por meio de uma determinada técnica de redução de incertezas, cujos melhores modelos são selecionados de acordo com uma tolerância para serem utilizados nas próximas etapas.

O AH é algumas vezes definido como um processo de otimização que busca reduzir a diferença entre o dado simulado e o dado observado (Gireli, 2016). No entanto, o objetivo não é apenas minimizar uma função-objetivo, mas também aumentar o conhecimento acerca do reservatório para reduzir as incertezas de forma confiável, sendo considerado um processo de assimilação de dados e redução de incertezas.

O AH é um problema inverso de múltiplas soluções, em que se conhece a resposta, mas não os atributos corretos que a reproduzem. Por ser um problema mal posto, diferentes soluções podem gerar bons ajustes com previsões da produção distintas, sendo essencial encontrar o máximo de soluções possíveis (que descrevem o comportamento passado do reservatório) para aumentar a confiabilidade nas previsões (Oliver e Chen, 2011).

Em geral, na indústria, o ajuste de histórico é uma das atividades mais críticas durante o gerenciamento de reservatórios e se torna mais complexa em função do número de poços, da quantidade de atributos incertos e múltiplas funções-objetivo (vazão de óleo e de água, etc.) a serem ajustadas (Bezerra, 2007). É recomendável que o AH seja realizado de forma probabilística, no qual múltiplas realizações são geradas para representar bem a variabilidade dos cenários gerados com a combinação dos atributos incertos do reservatório. No entanto, quanto maior o número de cenários maior a complexidade do problema, podendo aumentar significativamente o esforço computacional.

1.1 Ajuste de Histórico ao Longo do Tempo

A etapa de assimilação de dados (Etapas 3 a 5) é um processo dinâmico, no qual novos dados são incorporados continuamente com o objetivo de aumentar o conhecimento acerca do reservatório e calibrar os modelos de simulação (Chen *et al.*, 2009). Essa incorporação de dados pode ser realizada em ciclos (intervalos de tempo do período de histórico pré-determinados). Entre um ciclo e outro haverá uma diferença de dias, meses ou anos, sendo que o próximo ciclo terá o início com a disponibilidade de novas informações.

Basicamente, há três formas distintas de realizar o AH ao longo do tempo:

- 1) Ajuste de Histórico em Tempo Real (AHTR),
- 2) Ajuste de Histórico por Ciclos (AHC) e
- 3) Ajuste de Histórico por Divisão de Dados (AHDD).

Na forma 1 tem-se a conotação de ciclos mais curtos devido à necessidade de atualizar os modelos de reservatório de forma rápida e contínua, de modo que as previsões da produção e a incerteza associada estejam sempre atualizadas para os processos de análise de decisão/otimização da produção (Wen e Chen, 2005; Gu e Oliver, 2006). Geralmente, utiliza-se um gatilho (momento em que os modelos começam a desajustar) para se definir a necessidade de iniciar um novo ciclo, avaliando a qualidade do ajuste quando novos dados são adicionados.

A forma 2 é semelhante à forma 1. A diferença é que os ciclos são mais longos e definidos previamente, para atualizar os modelos de reservatório em cada ciclo, avaliando regularmente o seu comportamento para apoiar as tomadas de decisões (Bertolini, 2015; Silva, 2016a). Com relação ao início de um novo ciclo, há a possibilidade do uso de um gatilho tal como na forma 1 ou iniciá-lo automaticamente.

Por fim, a forma 3 consiste em dividir o dado disponível em partes para realizar o ajuste de histórico, ao invés de realizá-lo de forma integral considerando todo o histórico disponível (prática usual no AH tradicional). Esta forma se assemelha à forma 2, com a diferença quanto à disponibilidade do dado, que se encontra completamente disponível na forma 3. Um exemplo da forma 3 é o cálculo de uma função objetivo centrada no período de chegada de água nos poços produtores (*water breakthrough*).

Inúmeros métodos podem ser empregados para realizar o AH e dentre eles há o Filtro de Kalman (FK) e suas derivações, que realiza a integração do AH com a análise de incertezas de forma estatística com capacidade de gerar múltiplos modelos ajustados que representem de forma aproximada as incertezas do reservatório (Oliver e Chen, 2011).

O FK foi proposto originalmente em 1960, como uma metodologia sequencial de assimilação de dados criada para lidar com problemas lineares, entretanto, com o passar dos anos sofreu grandes modificações com o objetivo de lidar com problemas mais complexos. Dentre essas modificações, destaca-se o Filtro de Kalman por Conjunto (*Ensemble Kalman Filter* – EnKF) proposto inicialmente por Evensen (1994), que utiliza a técnica de Monte Carlo para amostrar probabilisticamente os atributos incertos e uma matriz de covariância para representá-los (Aanonsen *et al.*, 2009).

Posteriormente, van Leeuwen e Evensen (1996) propuseram uma nova abordagem, o Conjunto Suavizado (*Ensemble Smoother* – ES) capaz de assimilar os dados em uma única vez, no entanto, com uma menor qualidade do resultado em comparação ao EnKF. Com base nesses avanços, Emerick e Reynolds (2013) propuseram o Conjunto Suavizado com Múltiplas Assimilações de Dados (*Ensemble Smoother with Multiple Data Assimilation* – ES-MDA), capaz de gerar resultados semelhantes ao EnKF com menor esforço computacional.

Na literatura há poucos estudos sobre aplicações do ES-MDA em um processo de AHC, dentre eles há os trabalhos de Morosov (2016) e de Silva (2016a), nos quais o ES-MDA foi aplicado em um processo de AHC com o objetivo de obter modelos confiáveis para apoiar as decisões no desenvolvimento e gerenciamento de reservatório em malha fechada, respectivamente. Em ambos os trabalhos o método se mostrou eficiente para ajustar os modelos de simulação, no entanto, com algumas ressalvas quanto à redução excessiva de variabilidade de alguns atributos e divergência na previsão com relação à resposta real do problema no trabalho de Morosov (2016).

1.2 Motivação

Conforme exposto anteriormente, existem diversas metodologias capazes de realizar o AHC, dentre elas há o ES-MDA que por ser uma metodologia relativamente nova (Emerick e Reynolds, 2013), possui poucos trabalhos na literatura sobre aplicações em um processo de AHC.

Dentre os estudos, há o trabalho de Morosov (2016) que ao aplicar o ES-MDA em caso *benchmark* observou uma significativa redução da variabilidade dos atributos que resultou em divergência da resposta real. No entanto, Silva (2016a) ao aplicar o mesmo método, mas utilizando a técnica da localização (produto elemento por elemento – produto Schur – entre a matriz de correlação e o ganho de Kalman) dependente da distância, observou uma menor redução da variabilidade e mostrou que a previsão dos modelos ajustados contemplou a resposta real.

Nos trabalhos de Morosov (2016) e Silva (2016a), constatou-se a necessidade de voltar às incertezas a priori no início de cada ciclo como decorrência da redução excessiva das incertezas, descartando a possibilidade de aplicar as incertezas atualizadas (a posteriori) geradas pelo ES-MDA em um novo ciclo.

Por isso a maior motivação deste trabalho é avaliar outras formas de abordar as incertezas para iniciar um novo ciclo utilizando o ES-MDA. Além disso, é essencial testar as limitações deste método em um AHC e para isso a utilização de um caso *benchmark* com comportamento conhecido (UNISIM-I-M) é de fundamental importância para validar os resultados, uma vez que ao final do processo é possível comparar o resultado simulado com o modelo de referência.

1.3 Objetivos

O principal objetivo deste trabalho é testar o método ES-MDA com localização em um processo de AHC sob diferentes abordagens para atualizar as incertezas dos atributos entre os ciclos, usando um caso *benchmark* com comportamento conhecido (modelo de referência).

A fim de avaliar os resultados de forma coerente é essencial avaliar a variabilidade dos atributos incertos e a convergência do método ao longo dos ciclos, para verificar em qual das abordagens a redução das incertezas ocorre de forma consistente e não excessiva.

Além disso, é importante também avaliar a influência das abordagens na qualidade do ajuste e da previsão da produção em cada ciclo, evidenciando a melhor abordagem. No caso da previsão, é necessário verificar se os modelos ajustados contemplam o caso referência e se o método leva a uma redução excessiva e não desejada da variabilidade.

Por último, é realizada uma análise complementar, para verificar se os modelos considerados ajustados num dado ciclo conseguem manter o ajuste dos dados ao incorporar informações de um novo ciclo.

1.4 Organização da Dissertação

A presente dissertação está estruturada em 6 capítulos. O primeiro, corresponde à introdução, no qual o tema é contextualizado e também são descritos a motivação, o objetivo e a organização da dissertação. No Capítulo 2 é abordada a fundamentação teórica e revisão bibliográfica, estando presentes os principais conceitos teóricos para o entendimento do trabalho e o estado da arte de cada tópico importante envolvido neste trabalho. No Capítulo 3 é apresentada a descrição detalhada da metodologia. No Capítulo 4 é apresentada a aplicação baseada nas características do modelo e os dados utilizados. O Capítulo 5 contém os resultados obtidos e suas discussões. Por fim, no Capítulo 6, são discutidas as conclusões obtidas, bem como as recomendações para futuros trabalhos.

2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta os principais conceitos para o entendimento do trabalho, bem como o estado da arte com os principais trabalhos a respeito do ajuste de histórico ao longo do tempo e das derivações do Filtro de Kalman.

2.1 Análise de Decisão baseada em Modelos por Malha Fechada

A análise de decisão relacionada ao gerenciamento de reservatórios em malha fechada (*Closed Loop Reservoir Management – CLRM*) envolve riscos devido à presença de incertezas nas propriedades de rocha e fluido, modelo econômico e condições operacionais (Schiozer *et al.*, 2015). Segundo os autores, o risco envolvido pode ser estimado através da aplicação das principais etapas de um estudo de reservatórios para avaliar o efeito dessas incertezas e assim minimizar e/ou maximizar algum indicador (geralmente a produção de água, a produção de óleo ou o valor presente líquido – VPL) e melhorar o processo decisório.

A Figura 2.1 ilustra o fluxograma do CLRM. As partes em verde no fluxograma representam a aquisição de dados para caracterização de reservatórios e construção dos modelos de alta fidelidade (modelos com alto grau de representatividade das informações geológicas e de fluido). O processo de construção dos modelos, na maioria dos casos é complexo e a quantidade de informações acerca dos atributos é insuficiente para caracterizá-los adequadamente, sendo considerados incertos. Além disso, a utilização de modelos de alta fidelidade pode consumir muito tempo e, por este motivo, geralmente são utilizados para a geração, através de processos de transferência de escala, de modelos de média ou baixa fidelidade (modelos com médio ou baixo grau de representatividade das informações geológicas e de fluido) (Soares *et al.*, 2018).

Para aplicar o CLRM (Figura 2.1) é imprescindível ter um conjunto de modelos confiável que consiga reproduzir o comportamento do reservatório real. Como a presença de incertezas pode acarretar a geração de modelos que não reproduzem este comportamento de forma adequada, torna-se necessário realizar a assimilação de dados para reduzir as incertezas (AH) (vermelho) e gerar modelos mais representativos. Ao gerar modelos mais representativos é possível prosseguir para as etapas de análise de decisão (azul), que representam as aplicações em relação ao futuro.

Schiozer *et al.* (2015) desenvolveram uma metodologia baseada em 12 etapas para o CLRM. A metodologia envolve as principais etapas de um estudo de reservatórios, tais como caracterização de reservatórios sob incertezas e construção dos modelos de simulação,

assimilação de dados para redução de incertezas, análise de risco, seleção de modelos representativos e otimização da estratégia de produção. Essas etapas foram criadas de forma simples e flexível o suficiente para serem aplicadas em qualquer estágio de desenvolvimento de um campo.

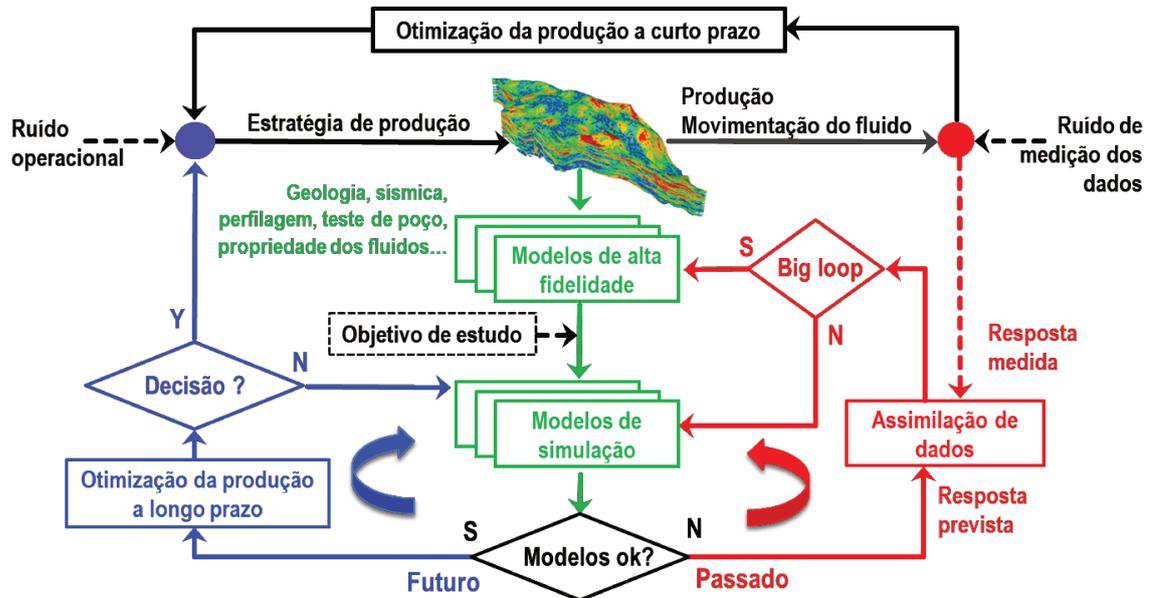


Figura 2.1: Processo de análise de decisão baseado em modelos por malha fechada (traduzido de Schiozer *et al.*, 2015)

2.2 Ajuste de Histórico

O ajuste de histórico (AH) é um processo de extrema importância para reduzir as incertezas que afetam a previsão da produção e com isso apoiar as decisões futuras com confiabilidade. Em linhas gerais, a confiabilidade nas previsões está relacionada com a capacidade do modelo em reproduzir o comportamento futuro do reservatório que, por sua vez, está relacionada com a capacidade de reproduzir o comportamento passado. No entanto, essa capacidade pode ser afetada pela quantidade de informações acerca do reservatório (Bertolini, 2015).

Aliado a este fato, normalmente a quantidade de dados disponíveis é insuficiente para quantificar de forma precisa os valores dos atributos, sendo por isso considerados incertos (Silva, 2016a). Devido à presença de incertezas, observa-se a geração de modelos que não reproduzem de forma precisa o comportamento do reservatório real. Sendo eles considerados inadequados para realizar a previsão da produção.

Este fato evidencia a necessidade de aplicação de um processo de assimilação de dados e redução de incertezas, conhecido na literatura como ajuste de histórico (Almeida, 2016). O AH consiste num problema inverso, em que se conhece a resposta – dados dinâmicos de produção (dados observados), mas não os atributos corretos que a reproduzem. Desta forma, esses atributos são alterados, respeitando os limites de incertezas, para honrar os dados dinâmicos de produção disponíveis (Silva, 2011).

Um importante aspecto do ajuste de histórico é a não unicidade de soluções. Em outras palavras, diferentes combinações de atributos podem resultar em ajustes igualmente aceitáveis com previsões da produção distintas (Oliver e Chen, 2011). Por este motivo, utilizar um único modelo ajustado não é considerado adequado, pois é improvável que o mesmo seja suficiente para apoiar as decisões de forma confiável. É cada vez mais comum a utilização de múltiplos modelos para tentar representar a faixa de incerteza de forma adequada (Silva, 2016a).

Dentro do contexto de múltiplas soluções diversos autores, como Moura Filho (2006), Silva (2011) e Costa (2012) retrataram o problema. Um exemplo da não unicidade de soluções é apresentado na Figura 2.2, que exibe o gráfico de vazão de água pelo tempo em um caso hipotético. Os pontos em vermelho representam o dado observado (histórico) e os pontos em preto, a previsão da produção do modelo de referência (conhecida apenas em casos sintéticos). A curva em azul claro representa o caso base (modelo a priori), em azul escuro o primeiro ajuste (Ajuste 1) e em verde o segundo ajuste (Ajuste 2).

Observa-se que, tanto o primeiro quanto o segundo ajuste apresentam graus de afastamento médio semelhantes em relação ao histórico. Em outras palavras, a curva em verde apresenta um bom ajuste até a primeira metade do tempo de histórico, enquanto que a curva em azul possui um melhor ajuste a partir da segunda metade do tempo de histórico. Ao realizar a previsão da produção, apesar do ajuste semelhante, somente o Ajuste 1 representou bem a previsão em relação à referência. Tal fato evidencia a possibilidade de diferentes combinações de atributos resultarem em ajustes semelhantes, mas com previsões da produção distintas.

Desta forma, um único modelo (abordagem determinística) não é suficiente para representar bem a faixa de incertezas dos atributos, sendo aconselhável o ajuste de histórico probabilístico com múltiplos modelos sendo ajustados simultaneamente.

O AH pode ser dividido em três classes: manual, automático e assistido. O manual, ainda bastante utilizado na indústria do petróleo, é realizado por meio de tentativa e erro. Sendo considerado um método bastante demorado, limitado quanto à busca de soluções e dependente da experiência do profissional no processo (Costa, 2012).

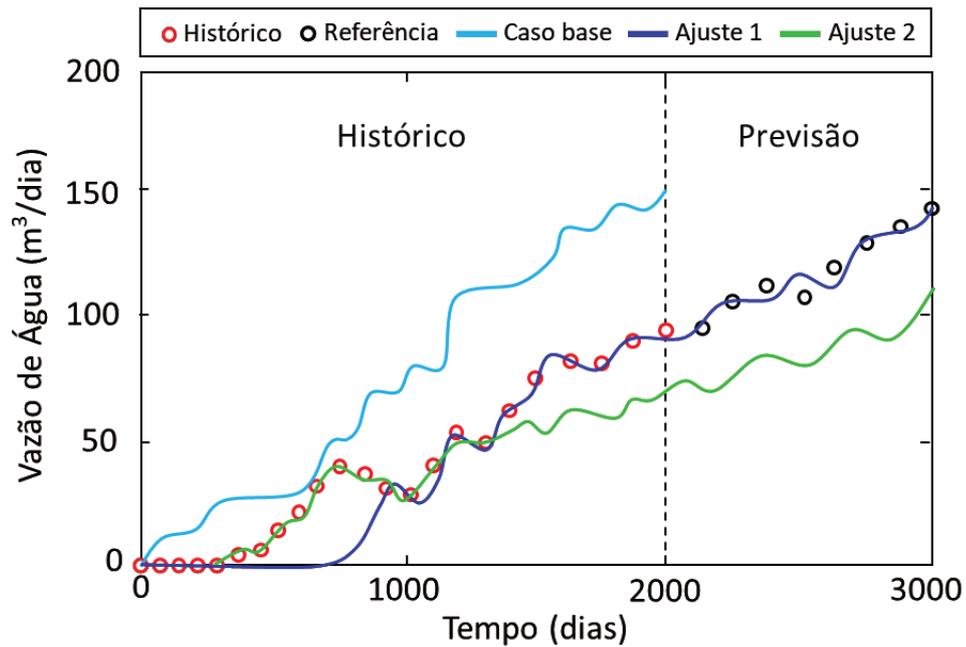


Figura 2.2: Exemplo de ajuste de histórico com múltiplas soluções.

No automático, diversos modelos são fornecidos a um programa e ao final do processo tem-se os modelos ajustados. Segundo Gireli (2016) o maior desafio está relacionado à parametrização automática dos atributos e à capacidade de lidar com todas as variáveis do problema, podendo elevar consideravelmente o número de simulações. Como alternativa há o ajuste assistido, que tem despertado maior interesse na indústria, devido a possibilidade de utilizar a experiência do profissional em todo o processo de AH para apoiar as principais decisões e através de um método automático, realizar o ajuste de histórico (Soares, 2017).

2.2.1 Função Objetivo

A avaliação da qualidade do ajuste de histórico é uma etapa fundamental e é realizada utilizando uma função objetivo (FO) para avaliar a qualidade dos modelos através da mensuração do desvio entre os dados simulados e observados.

Silva (2016b) por meio de uma breve revisão bibliográfica citou diferentes maneiras para se definir uma FO e sua complexidade. Tradicionalmente, o processo de ajuste de histórico utilizava uma única FO de maneira global para representar todos os dados disponíveis. No entanto, com o passar dos anos passou a ser aplicada como uma função multiobjetivo, onde cada variável é analisada separadamente.

Dentre as medidas de desvio há o Afastamento Quadrático Normalizado com Sinal (AQNS), definido a seguir conforme Maschio e Schiozer (2016).

Primeiramente é calculado o afastamento simples (A):

$$A = \sum_{l=1}^{N_{obs}} (d_{sim,l} - d_{obs,l}) \quad (2.1)$$

sendo $d_{obs,l}$ os dados observados, $d_{sim,l}$ os dados simulados e N_{obs} o número de dados observados.

O próximo passo é o cálculo do afastamento quadrático com sinal (AQS):

$$AQS = \frac{A}{|A|} \sum_{l=1}^{N_{obs}} (d_{sim,l} - d_{obs,l})^2 \quad (2.2)$$

Em seguida calcula-se o afastamento quadrático aceitável (AQA):

$$AQA = \sum_{l=1}^{N_{obs}} (Tol * d_{obs,l} + C)^2 \quad (2.3)$$

sendo Tol a tolerância (porcentagem) e C uma constante adicionada aos dados observados. O acréscimo da constante C é utilizado para evitar valores nulos de AQA em série de dados que possuem valores nulos no período de histórico.

Por último calcula-se o AQNS:

$$AQNS = \frac{AQS}{AQA} \quad (2.4)$$

Conforme Maschio e Schiozer (2016), valores de AQNS dentro do intervalo $[-1, +1]$ significam que a diferença entre o dado simulado e observado é da mesma ordem de magnitude do desvio aceitável (representado por Tol e C). O intervalo $[-1, +1]$ para o AQNS é a meta final do ajuste. Porém, para casos complexos, é muito difícil obter todas as funções dentro da faixa $[-1, +1]$, podendo ser necessário relaxar o critério de aceitação para faixas maiores de AQNS de acordo com a complexidade do caso e com o objetivo do estudo.

2.2.2 Integração entre o Ajuste de Histórico e Análise de Incertezas

A incerteza, segundo Silva (2011), está relacionada com a falta de informações acerca dos atributos do reservatório (porosidade, permeabilidade, contato óleo-água e outros). Geralmente, poucas informações que existem a respeito dos reservatórios marítimos são obtidas de forma direta (dados de poços) devido ao elevado custo de perfuração. A maior parte das informações é estimada, correlacionada ou inferida devido à dimensão do campo (Costa, 2012). Por este motivo, as informações disponíveis são insuficientes para caracterizar os atributos de forma precisa.

Segundo Becerra (2007), a presença de incertezas afeta diretamente a previsão da produção, gerando riscos nas decisões de um projeto. Portanto, a quantificação dessas incertezas é uma etapa essencial dentro do ajuste de histórico (integrado com a análise de incertezas) para avaliar o risco e tomar uma decisão bem fundamentada (Soares, 2017).

Moura Filho, Becerra (2007) e Maschio *et al.* (2010) apresentaram metodologias probabilísticas para integrar a análise de incertezas com ajuste de histórico. Essas metodologias têm como base a redistribuição das probabilidades dos atributos para restringir a amplitude de incertezas. Para representar essas incertezas é comum a utilização de funções de densidade de probabilidade (pdf) (Figura 2.3).

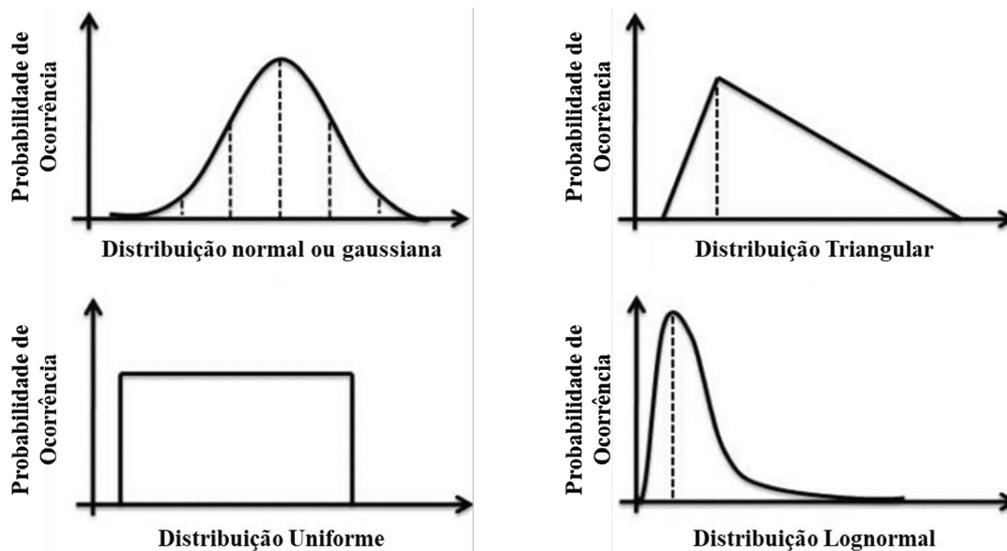


Figura 2.3: Exemplos de distribuições probabilísticas (adaptado de Silva, 2011).

Segundo Maschio e Schiozer (2014), a estatística Bayesiana pode ser utilizada como base para relacionar os dados dinâmicos de produção na quantificação de incertezas. Dentro deste contexto, mais recentemente, segundo Silva (2016b), alguns autores como (Cominelli *et al.*,

2009 e Emerick e Reynolds, 2012) empregaram métodos derivados do Filtro de Kalman para integrar o ajuste de histórico à análise de incertezas

2.3 Ajuste de Histórico ao Longo do Tempo

Segundo Silva (2011) o ajuste de histórico é considerado um processo dinâmico, pois novos dados são incorporados continuamente para atualizar os modelos de simulação até o fim da vida útil do reservatório. Idealmente, sempre que há a disponibilidade de um novo dado observado realiza-se o ajuste de histórico, no entanto, na prática nem sempre isso é possível devido à disponibilidade de recursos humano e computacional.

Essa incorporação de novos dados é importante para aumentar o conhecimento acerca do reservatório e reduzir as incertezas de forma mais confiável (Chen *et al.*, 2009). O novo dado observado pode ser incorporado em ciclos (intervalos de tempo de histórico pré-determinados). Com base na definição dos ciclos o ajuste de histórico ao longo do tempo pode ser realizado sob três formas distintas: ajuste de histórico em tempo real, ajuste de histórico por ciclos e ajuste de histórico por divisão de dados, definidas a seguir.

2.3.1 Ajuste de Histórico em Tempo Real

No ajuste de histórico em tempo real (AHTR), normalmente, os ciclos são mais curtos devido à necessidade de atualizar os atributos do reservatório de forma rápida e contínua para apoiar as tomadas de decisões. Um exemplo esquemático do AHTR é apresentado na Figura 2.4. O eixo das abcissas mostra os diferentes tempos de histórico (t_1 , t_2 e t_3) e o eixo das ordenadas representa o ajuste de histórico nos diferentes ciclos (Ciclo 1, Ciclo 2 e Ciclo 3), representados pelas setas em azul. A seta em verde se refere à previsão da produção após o ajuste em cada ciclo.

Como o ajuste de histórico pode ser aplicado em qualquer estágio de um campo de petróleo, considera-se um tempo inicial (t_1). Desta forma, o primeiro ajuste é realizado até o tempo t_1 (Ciclo 1) (Figura 2.4a). O Ciclo 2 se inicia com a disponibilidade do dado observado até o tempo t_2 (Figura 2.4b). A diferença entre o tempo t_1 (Ciclo 1) e o tempo t_2 (Ciclo 2) é que define a conotação de ciclos mais curtos no AHTR. O Ciclo 3, da mesma forma que no Ciclo 2, se inicia com a disponibilidade do dado até o tempo t_3 (Figura 2.4c). Adicionalmente, para se iniciar um novo ciclo, utiliza-se um gatilho para avaliar a qualidade do ajuste e definir a necessidade de iniciar um novo ciclo.

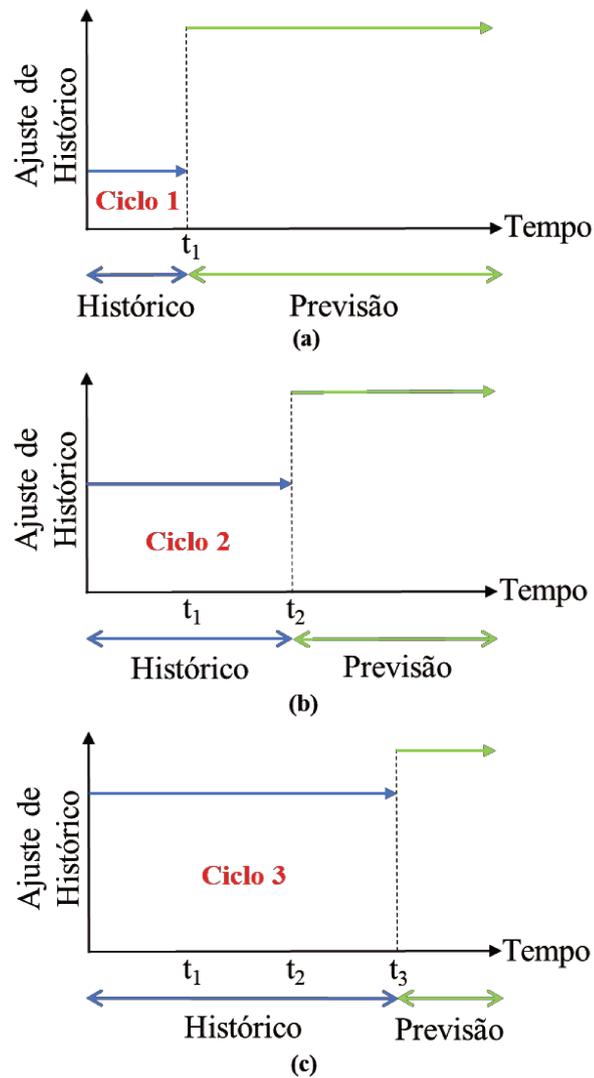


Figura 2.4: Exemplo do ajuste de histórico em tempo real.

Segundo Oberwinkler e Stundner (2004), o termo “tempo real” geralmente significa reagir a um evento instantaneamente ou dentro de um curto intervalo de tempo. No entanto, na indústria do petróleo, este curto intervalo de tempo pode ser de horas, dias ou até mesmo semanas. A definição do intervalo de tempo de um ciclo depende do objetivo do estudo, por exemplo, pode-se dar foco ao período de chegada de água nos poços produtores, e da disponibilidade de recursos humano e computacional para a execução.

A evolução da implantação de sensores permanentes para monitoramento do reservatório, como os de vazão e pressão, aumentou consideravelmente a disponibilidade desses dados e com isso a demanda por modelos ajustados em tempo real (Gu e Oliver, 2006). Segundo o autor, esta evolução permitiu incorporar os dados assim que eles são obtidos para que o modelo esteja sempre atualizado, ao invés de registrar os dados ao longo de um certo tempo para posteriormente realizar o ajuste.

Segundo Wen e Chen (2005), para que um AHTR seja eficiente, é necessário que o método utilizado para atualizar os modelos de simulação seja capaz de ajustá-los de forma rápida e contínua. Sendo este, de extrema importância para atualizar as previsões da produção e a incerteza associada no processo de análise de decisão em malha fechada. Dentro deste contexto, o AHTR permite que as decisões sejam tomadas o mais rápido possível para maximizar o potencial de produção de um reservatório (Jansen *et al.*, 2005). No entanto, na prática nem sempre é possível atualizar os modelos de forma rápida (em um curto intervalo de tempo) em função da disponibilidade de recursos (humano e computacional) para a sua execução.

De acordo com a literatura, o Filtro de Kalman por Conjunto (*Ensemble Kalman Filter – EnKF*) é considerado um dos métodos mais adequados devido à sua capacidade de assimilar os dados sequencialmente no tempo (Gu e Oliver, 2006; Wen e Chen, 2005; Chen *et al.*, 2009).

2.3.2 Ajuste de Histórico por Ciclos

No ajuste de histórico por ciclos (AHC), o processo de ajuste é semelhante ao AHTR, no entanto, os ciclos são mais longos e definidos previamente por meio de um intervalo de tempo de histórico. Este intervalo de tempo pode ser fixo ou variável ao longo dos ciclos, sendo dependente do objetivo do estudo. A atualização dos modelos em cada ciclo é realizada regularmente para avaliar o comportamento do reservatório e apoiar as tomadas de decisões. Por se tratar de ciclos mais longos é possível realizar um ajuste mais elaborado, sem muitas simplificações.

Bertolini (2015) destacou os desafios e a importância da atualização dos modelos de simulação a partir da incorporação de novas informações (ciclos) ao longo do tempo. Com base nesses desafios, o autor propôs uma metodologia sequencial de avaliação do ajuste ao longo do tempo composta por 9 passos. Essa metodologia permite a aplicação de um método para reduzir as incertezas e um gráfico de rastreamento para avaliar a qualidade do modelo ajustado.

O AHC é constantemente combinado com processos de gerenciamento de reservatórios devido à necessidade de gerar modelos confiáveis para realizar a previsão da produção e assim minimizar e/ou maximizar algum indicador (geralmente econômico) (Chen *et al.*, 2009). Segundo Wang *et al.* (2009), no gerenciamento de reservatórios o ajuste de histórico é repetido em tempos específicos (ciclos) para atualizar os modelos de simulação e determinar condições operacionais ótimas para maximizar a produção de hidrocarbonetos ou o VPL.

Wang *et al.* (2009) aplicou o EnKF em um processo de AHC para estimar a porosidade e permeabilidade absoluta ao longo do tempo. Apesar do procedimento sequencial de ajuste do

EnKF, o autor utilizou ciclos longos para analisar os resultados do ajuste da última assimilação. Inicialmente, constatou-se que o método apresenta dificuldades para ajustar os modelos devido à escassez de dados observados, no entanto, com o aumento das informações o ajuste melhora a cada ciclo. Os autores constataram que, ao final do último ciclo, os atributos analisados apresentaram certa semelhança ao resultado verdadeiro.

Morosov (2016) aplicou o Conjunto Suavizado com Múltiplas Assimilações de Dados (*Ensemble Smoother with Multiple Data Assimilation – ES-MDA*) sem a técnica da localização em um processo de desenvolvimento de reservatórios em malha fechada (*Closed Loop Field Development – CLFD*) para gerar modelos ajustados e apoiar as decisões futuras. No entanto, ao comparar os resultados ao longo dos ciclos, destacou que o método acabou reduzindo a variabilidade dos atributos de forma excessiva, principalmente para permeabilidade relativa da água (k_{rw}). Em função desta redução excessiva da variabilidade, o resultado simulado acabou divergindo da resposta real do problema (modelo de referência).

Silva (2016a) apresentou um estudo semelhante ao de Morosov quanto ao processo de ajuste, no entanto, aplicado ao gerenciamento de reservatórios em malha fechada (CLRM). O autor utilizou o mesmo método de redução de incertezas, o ES-MDA, porém utilizando a técnica da localização. O resultado mostrou que apesar da grande redução da variabilidade o método conseguiu alcançar bons resultados; sendo que, após o período de histórico, foi possível contemplar a resposta do modelo de referência.

2.3.3 Ajuste de Histórico por Divisão de Dados

No ajuste de histórico por divisão de dados (AHDD), o dado disponível é dividido em várias partes para realizar o ajuste de histórico com foco em determinado intervalo de tempo. Em outras palavras, ao invés de realizar o ajuste de forma integral considerando todo o período de histórico disponível, realiza-se o ajuste de histórico por partes, com base da divisão do dado observado disponível. Por exemplo, realizar o ajuste antes da chegada de água e depois da chegada de água.

Dentro dessa linha, o grupo de pesquisa UNISIM está trabalhando nesse processo de quebra de série de dados para melhorar a qualidade do ajuste. Essa quebra pode ser realizada por diferentes formas, além da divisão do dado disponível em partes.

Almeida *et al.* (2018), introduziram duas formas de calcular uma FO, a primeira relacionada ao cálculo de uma função objetivo centrada no período de chegada de água nos poços produtores (*water breakthrough*) e a segunda relacionada ao comportamento de transição entre o período de histórico e de previsão da produção. O objetivo de quebrar a FO em partes é

capturar comportamentos específicos que a FO tradicional, referente ao histórico completo, pode não revelar, como por exemplo, identificar quais atributos influenciam antes e após a chegada de água nos poços produtores.

2.4 Filtro de Kalman e suas derivações

O EnKF foi proposto por Evensen (1994) como uma alternativa para o tradicional Filtro de Kalman (FK). O EnKF representa as incertezas através de um conjunto de vetores de estado e é capaz de solucionar problemas não lineares e com grande quantidade de dados (Evensen, 2009). Vale ressaltar que devido ao procedimento sequencial de assimilação é necessário reiniciar a simulação a cada passo de tempo e isso pode aumentar significativamente o custo computacional (Emerick, 2016).

Para evitar a reinicialização da simulação do EnKF, van Leeuwen e Evensen (1996) propuseram uma nova abordagem capaz de assimilar os dados em uma única vez, o Conjunto Suavizado (*Ensemble Smoother* – ES), que foi aplicado pela primeira vez em ajuste de histórico por Skjervheim *et al.* (2011). O maior avanço do ES foi a eliminação da necessidade de reiniciar a simulação a cada passo tempo, fato que contribuiu para reduzir o tempo de simulação em até 10 vezes em comparação com EnKF (Skjervheim *et al.*, 2011).

Emerick e Reynolds (2013) evidenciaram que essa assimilação simultânea do ES causa uma redução na qualidade do ajuste em comparação com o EnKF. Diante disto, propuseram uma nova abordagem, o ES-MDA, que possui uma forma iterativa mais eficiente do que o ES e neste caso mais de uma iteração é realizada.

2.5 ES-MDA com Localização

Ao apresentarem o ES-MDA como uma alternativa para a baixa qualidade do ajuste dos dados de produção do método ES, Emerick e Reynolds (2013) destacaram que esta metodologia iterativa melhora a qualidade do ajuste a cada iteração. Tal proposição tem como base o ES e é necessário definir previamente o número de iterações.

Emerick e Reynolds (2013) realizaram uma comparação entre os métodos EnKF, ES e ES-MDA em casos sintéticos e mostraram que o ES-MDA, embora com um maior número de simulações, apresentou melhores ajustes dos dados de produção. Entretanto, salientou que a redução da variabilidade do conjunto se trata de um resultado esperado, devido ao procedimento iterativo da metodologia que busca em cada iteração soluções menos independentes e com melhores qualidades de ajuste de histórico. Cabe ressaltar que, embora o número de simulações do ES-MDA seja maior, o tempo computacional do ES-MDA é da mesma ordem do EnKF,

pois o EnKF consome tempo computacional reiniciando a simulação a cada passo de tempo no qual se deseja assimilar o dado.

Segundo Aanonsen *et al.* (2009), a redução do tamanho de conjunto pode resultar em problemas de amostragem e conseqüentemente correlações espúrias, que através de modificações inconsistentes em regiões do reservatório sem influência no fluxo, reduzem de forma excessiva a variabilidade. O aumento do número de modelos, apesar de reduzir os problemas citados, aumenta consideravelmente o esforço computacional, e como alternativa para os problemas citados, surgiu a técnica da localização dependente da distância que reduz os problemas de correlações espúrias e aumenta a variabilidade do conjunto (Emerick e Reynolds, 2011).

A técnica da localização é fundamental para lidar com as limitações do procedimento *standard* do ES-MDA (sem localização), que pode resultar em modificações inconsistentes em regiões do reservatório sem influência no fluxo, chamadas de correlações espúrias (Emerick, 2016). Esta técnica é formada pela multiplicação elemento por elemento, produto Schur (\circ), entre uma matriz de correlação (ρ) e a matriz do ganho de Kalman (K), de acordo com a Equações (2.5) e (2.6):

$$m_j^{i+1} = m_j^i + \rho \circ K (d_{obs,j} - d_{sim,j}) \quad (2.5)$$

$$K = C_{MD}^i (C_{DD}^i + \alpha_i C_D)^{-1} \quad (2.6)$$

onde m_j^{i+1} é o conjunto atualizado, m_j^i o conjunto inicial ($\{m_j^i\}_{j=1}^{N_e}$), α_i o coeficiente de inflação, $d_{obs,j}$ os dados observados, $d_{sim,j}$ o conjunto simulado, C_{DD} a matriz de auto covariância dos dados simulados do conjunto, C_D a matriz de covariância dos erros de medição, C_{MD} a matriz de covariância cruzada entre os parâmetros do modelo e os dados observados, N_e o número de modelos e i as iterações.

A assimilação dos dados de cada poço é realizada somente na região de influência delimitada por ρ , o qual dependerá do tipo de localização utilizado, sendo que fora da região de influência, o valor de ρ é igual a zero e por isso os dados não são assimilados nesta região (Aanonsen *et al.*, 2009).

Existem diferentes maneiras para definição de ρ , a qual depende do tipo de localização a ser utilizado. Gaspari e Cohn (1999) descreveram uma formulação para o cálculo da matriz de correlação, a qual é dependente da distância, sendo que cada célula da malha terá um valor

diferente. Esta formulação é uma das mais utilizadas na literatura e baseia-se em uma função que relaciona a distância do centro do poço a qualquer ponto da malha, conforme a Equação (2.7):

$$\rho(h, L) = \begin{cases} -\frac{1}{4} \left(\frac{h}{L}\right)^5 + \frac{1}{2} \left(\frac{h}{L}\right)^4 + \frac{5}{8} \left(\frac{h}{L}\right)^3 - \frac{5}{3} \left(\frac{h}{L}\right)^2 + 1, & 0 \leq h \leq L \\ \frac{1}{12} \left(\frac{h}{L}\right)^5 - \frac{1}{2} \left(\frac{h}{L}\right)^4 + \frac{5}{8} \left(\frac{h}{L}\right)^3 - \frac{5}{3} \left(\frac{h}{L}\right)^2 - 5 \left(\frac{h}{L}\right) + 4 - \frac{2}{3} \left(\frac{h}{L}\right)^{-1}, & L \leq h \leq 2L \\ 0, & h > 2L \end{cases} \quad (2.7)$$

onde h representa a distância euclidiana entre o centro do poço e qualquer ponto da malha e L a distância crítica, que irá delimitar a região de influência.

Emerick e Reynolds (2011) com base na formulação de Gaspari e Cohn (1999) propuseram uma nova aplicação para representar os modelos anisotrópicos, a qual é baseada na distância euclidiana nas direções x e y representadas através de uma elipse (Figura 2.5) que define as regiões de influência, conforme as Equações (2.8) e (2.9):

$$\begin{bmatrix} h_{x'} \\ h_{y'} \end{bmatrix} = \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} h_x \\ h_y \end{bmatrix} \quad (2.8)$$

onde θ representa o ângulo de rotação da elipse e $h_{x'}$ e $h_{y'}$ as distâncias do eixo x e y rotacionados pelo ângulo θ .

$$h = \sqrt{\left(\frac{h_{x'}}{L_x}\right)^2 + \left(\frac{h_{y'}}{L_y}\right)^2} \quad (2.9)$$

onde, L_x e L_y representam as distâncias críticas.

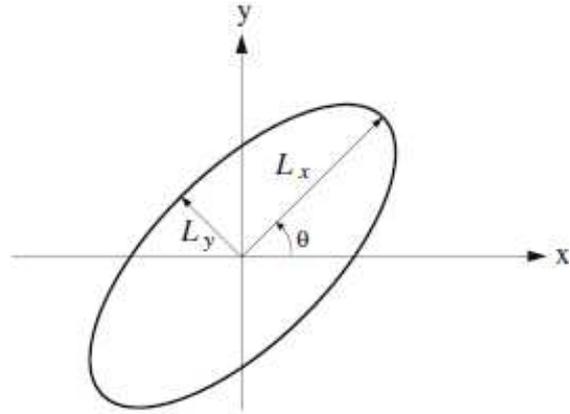


Figura 2.5: Representação da região de localização definida por uma elipse (Emerick e Reynolds, 2011).

3 METODOLOGIA

A metodologia desenvolvida neste trabalho é baseada na aplicação do ES-MDA com localização em um processo de AHC sob diferentes abordagens para atualizar as incertezas dos atributos, definidas como escalares e espaciais. A Figura 3.1 mostra o fluxograma do processo de AHC, dividido em 6 etapas.

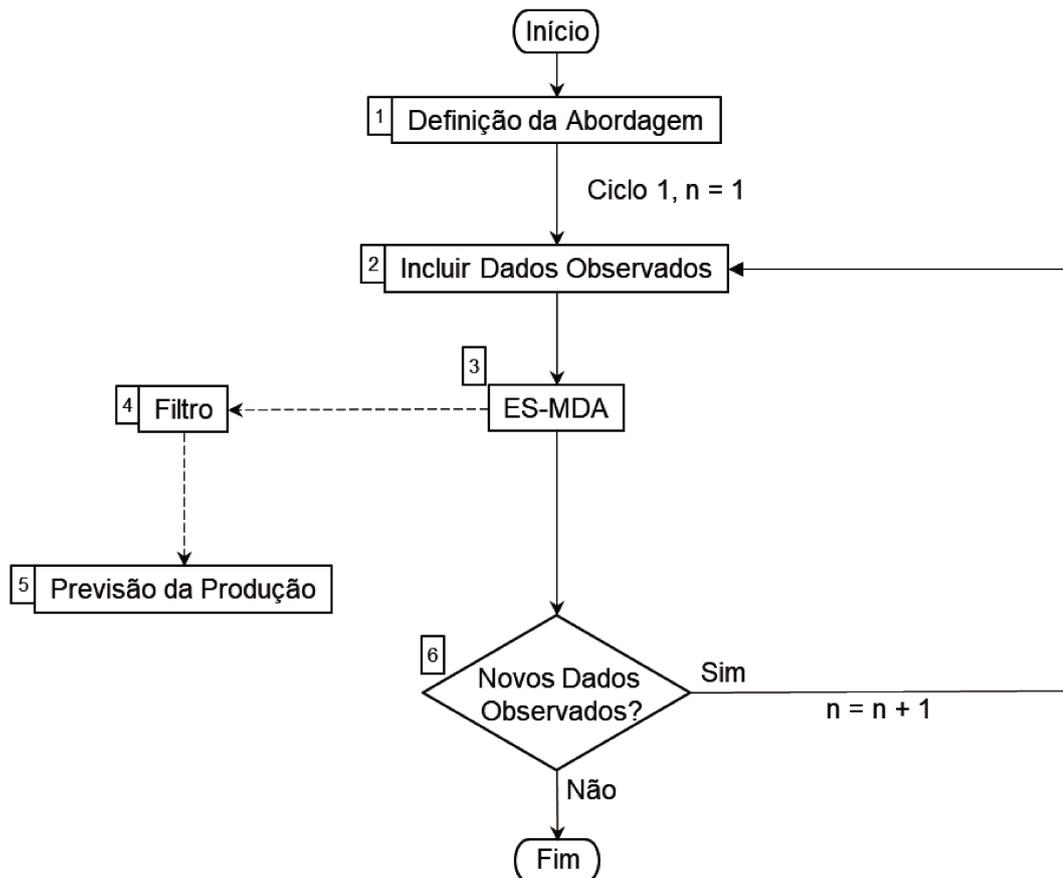


Figura 3.1: Fluxograma do processo de ajuste de histórico por ciclos sob diferentes abordagens.

3.1 Etapa 1: Definição da Abordagem

A primeira etapa representa o início do processo de AHC através da definição da abordagem. A abordagem é baseada na forma de lidar com as incertezas escalares e espaciais para atualizá-las no processo de ajuste de histórico utilizando o ES-MDA e pode ser realizada sob diferentes maneiras.

Neste trabalho foram definidas três diferentes abordagens (A, B e C), descritas a seguir:

- 1) Abordagem A: entre um ciclo e outro, são utilizadas sempre as mesmas incertezas a priori do Ciclo 1 (tomando como exemplo o *benchmark* UNISIM-I-M, é o conjunto das 500 imagens (realizações geoestatísticas) geradas usando um software de modelagem (por exemplo, Petrel) mais os atributos escalares (tais como permeabilidade relativa, contato óleo-água e etc.). No caso das variáveis escalares, os limites originais são impostos de acordo com valores mínimo e máximo para se definir uma distribuição triangular (usada neste trabalho). A Figura 3.2 mostra a distribuição de probabilidade a priori de um atributo escalar (que no caso desta abordagem é definido conforme Figura 3.3a) como entrada no ES-MDA (antes do ajuste) e, após o ajuste de histórico, uma nova distribuição (a posteriori) é gerada na saída.
- 2) Abordagem B: nessa abordagem, as incertezas a priori de um determinado ciclo (a partir do segundo) correspondem às incertezas a posteriori (saída do ES-MDA) do ciclo anterior. No caso das imagens (variáveis espaciais), são as imagens geradas pelo ES-MDA no último conjunto do ajuste do ciclo anterior. No caso das variáveis escalares, novos limites são impostos de acordo com valores mínimo e máximo gerados no último conjunto do ajuste do ciclo anterior para se definir uma distribuição triangular, conforme Figura 3.3b. Devido à imposição de novos limites, possivelmente o método pode reduzir de forma excessiva a variabilidade dos atributos escalares e por isso é necessário avaliar em cada ciclo a necessidade de reparametrizar os seus limites.
- 3) Abordagem C: a definição desta abordagem é semelhante à Abordagem B. A diferença é que, para as variáveis escalares, ao invés de definir uma distribuição triangular tal como nas abordagens A e B, aplica-se exatamente a distribuição fornecida pela saída do ES-MDA do ciclo anterior (último conjunto do ajuste) e os limites originais são mantidos, conforme Figura 3.3c, e por este motivo não é preciso reparametrizar os limites dos atributos escalares.



Figura 3.2: Exemplo de distribuição a priori (antes do ajuste) e posteriori (após o ajuste).

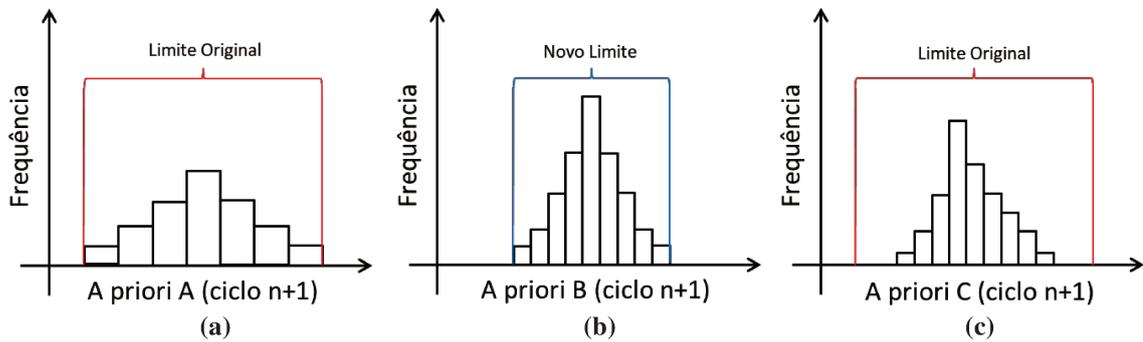


Figura 3.3: Definição dos atributos escalares nas diferentes abordagens.

Por fim, ressalta-se que os limites dos atributos espaciais em todas as abordagens são definidos conforme os originais do modelo. Essa definição é realizada para evitar a redução excessiva da variabilidade das imagens e para que o método não extrapole para valores fora da faixa plausível para o caso em estudo. Vale a pena destacar que para reparametrizá-los seria necessário gerar novas imagens usando um software de modelagem geoestatística (Petrel, por exemplo). A reparametrização é recomendada quando os modelos de simulação gerados não englobam o histórico ou quando o método realiza o truncamento dos atributos escalares para respeitar os novos limites estabelecidos. Ela pode ser aplicada, quando necessária, na Etapa 3 (ES-MDA).

Após a definição da abordagem, o próximo passo é a inclusão de dados observados (Etapa 2).

3.2 Etapa 2: Incluir Dados Observados

A segunda etapa se refere à inclusão dos dados observados (histórico) de um determinado ciclo para gerar um modelo base. Este modelo servirá de base para as próximas etapas.

3.3 Etapa 3: ES-MDA

A terceira etapa representa a aplicação do método ES-MDA com a técnica da localização de acordo com a abordagem definida na Etapa 1.

Nesta etapa é realizada uma comparação dos resultados entre as três abordagens (A, B e C) para analisar a evolução da qualidade do ajuste dos dados e a redução das incertezas dos atributos ao longo dos ciclos. O principal propósito desta comparação é identificar as limitações de cada abordagem e determinar a melhor forma de realizar o AHC com base nas abordagens definidas. Nessa etapa, a avaliação dos resultados é dividida em duas partes: análise da qualidade do ajuste e análise das incertezas.

3.3.1 Aplicação do ES-MDA

O processo de aplicação do ES-MDA é baseado no procedimento descrito no trabalho de Emerick (2016).

Para formar o conjunto inicial que servirá de base para o processo de assimilação de dados em cada ciclo é preciso definir dois itens:

- Número de modelos (N_e) que compõe o conjunto; e
- As incertezas escalares e espaciais, bem como a sua parametrização.

Além da definição do conjunto inicial, é preciso definir os parâmetros iniciais do processo de assimilação de dados em cada ciclo:

- Número de assimilações (N_i);
- Coeficiente de inflação (α_i);
- Método de inversão das matrizes (C_{DD} e C_D);
- Variáveis assimiladas;
- Desvio padrão representativo do erro de medição de cada variável assimilada;
- Escolher a forma de se definir a região de localização.

3.3.2 Análise da qualidade do ajuste

A análise da qualidade do ajuste é realizada utilizando um FO multiobjetivo. Essa análise é feita em dois momentos em cada ciclo: (1) após o ajuste de um determinado ciclo e (2) após a inclusão dos dados do ciclo seguinte (antes do ajuste do ciclo seguinte). Por exemplo, suponha que o primeiro ciclo tenha 360 dias de histórico e o segundo 540 dias. Primeiramente, realiza-se o ajuste (usando o ES-MDA) até 360 dias e calcula-se o AQNS de todas as funções objetivo. Em seguida, adicionam-se os 180 dias de histórico aos modelos ajustados e calcula-se o AQNS de 0 a 540 dias. O objetivo é avaliar a qualidade do ajuste dos dados após a aplicação do ES-MDA e verificar se os modelos continuam ajustados após a inclusão dos novos dados.

A Figura 3.4 mostra um exemplo da aplicação da nomenclatura para a Abordagem A ao longo dos ciclos. $(A_1)pr_1$ significa Abordagem A, Ciclo 1, inclusão dos dados observados até o Ciclo 1 (antes do ajuste); $(A_1)pt_1$ significa Abordagem A, Ciclo 1, inclusão dos dados observados até o Ciclo 1 (após o ajuste). Para os outros ciclos, o significado é o mesmo, bastando mudar o número do ciclo.

Para as abordagens B e C a nomenclatura é a mesma, bastando trocar a letra da abordagem, no entanto, o seu início se dá a partir do Ciclo 2. Caso ocorra a reparametrização

dos atributos escalares na Abordagem B, o número do ciclo (n) sofre uma modificação para indicá-las. Por exemplo, na primeira reparametrização acrescenta-se o algarismo “1”, $(B_2)pt_{2,1}$, na segunda, o algarismo “2”, $(B_2)pt_{2,2}$, e assim por diante.

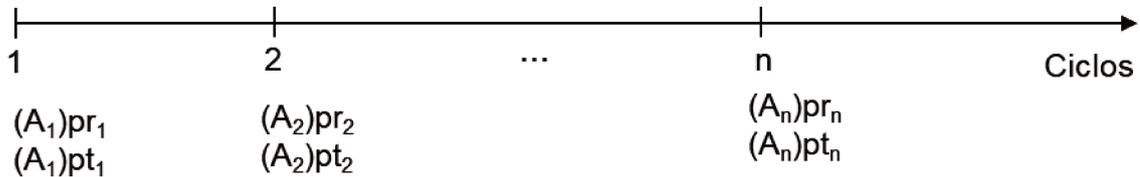


Figura 3.4: Exemplo da aplicação da nomenclatura para a Abordagem A ao longo dos ciclos, a priori (antes do ajuste) e a posteriori (após o ajuste).

3.3.3 Análise das incertezas

A análise das incertezas é baseada na comparação dos atributos incertos em cada ciclo. O objetivo é avaliar a redução da variabilidade dos atributos espaciais e escalares, verificando a ocorrência de redução excessiva da variabilidade e convergência do método ao longo dos ciclos nas diferentes abordagens. Para estas análises são utilizados os seguintes indicadores:

- Média e desvio padrão das imagens dos atributos espaciais;
- Histograma, valores de desvio padrão normalizado e média dos atributos escalares.

3.4 Etapa 4: Filtro

A etapa de filtragem é realizada através da definição de um valor aceitável para cada FO, para que os modelos aceitos de acordo com essa faixa de aceitação sejam selecionados. Este processo é importante, pois, mesmo com a aplicação bem-sucedida do ajuste de histórico, alguns modelos podem não honrar o histórico para todas as funções simultaneamente, sendo recomendável, quando possível, eliminá-los do próximo passo (previsão da produção).

3.5 Etapa 5: Previsão da Produção

A previsão da produção é realizada primeiramente no conjunto de modelos a priori do primeiro ciclo e posteriormente no conjunto de modelos a posteriori de cada ciclo sem o filtro. Após esta previsão, realiza-se a previsão dos modelos filtrados de cada ciclo. Esta etapa é importante para analisar a variabilidade da previsão da produção e verificar se o conjunto de modelos filtrados contempla a resposta real (conhecida apenas em casos sintéticos).

A redução da variabilidade da previsão ao longo dos ciclos é um resultado esperado e gera uma maior confiabilidade nos resultados obtidos, entretanto, a presença de variabilidade é importante para aumentar as chances de contemplar a resposta real. Desta forma, espera-se encontrar a abordagem que apresenta uma maior porcentagem de modelos filtrados, contemplando a resposta real.

3.6 Etapa 6: Novos Dados Observados?

A sexta etapa representa uma verificação da disponibilidade de novos dados observados para iniciar um novo ciclo. No caso dos dados estarem disponíveis, inicia-se um novo ciclo (n+1) a partir da inclusão dos novos dados observados na Etapa 2. No caso da não disponibilidade, o processo é encerrado, e os modelos ajustados do ciclo atual continuam sendo a base para a previsão da produção até que novos dados estejam disponíveis para se iniciar um novo ciclo.

4 APLICAÇÃO

Desde as primeiras simulações e estudos de reservatórios, diversas metodologias relacionadas às aplicações de gerenciamento de reservatórios têm sido criadas no sentido de apoiar as tomadas de decisões com maior confiabilidade. Para desenvolver e validar diferentes metodologias é importante utilizar casos *benchmark* com comportamento conhecido que reproduzem o gerenciamento de campos de petróleo sob incertezas.

A metodologia descrita foi aplicada em um caso *benchmark* com resposta conhecida, denominado UNISIM-I-M. O caso foi criado a partir de um modelo refinado (UNISIM-I-R) baseado em informações do campo de Namorado, localizado na Bacia de Campos, Brasil. O campo de Namorado consiste em um arenito de origem turbidítica, conhecido como Arenito de Namorado.

O UNISIM-I-R é considerado um modelo de alta resolução, construído para representar um reservatório real e validar as metodologias pela comparação das respostas dos modelos simulados com o reservatório real na previsão da produção.

O UNISIM-I-M é considerado um modelo de média resolução e representa o modelo de simulação sob incertezas. Este modelo foi desenvolvido especificamente para atividades de pesquisa em análise de decisão no gerenciamento de reservatórios, período após a implementação da estratégia de produção. Maiores detalhes sobre o caso podem ser encontrados em Avansi e Schiozer (2015) e Gaspar *et al.* (2016), bem como no seguinte link: <https://www.unisim.cepetro.unicamp.br/benchmarks/br/unisim-i>.

4.1 UNISIM-I-M

O modelo de reservatórios UNISIM-I-M é representado por uma malha *corner point* com 81 x 58 x 20 células (36.739 células ativas), medindo em média 100 x 100 x 8 m. O óleo deste reservatório é de boa qualidade (28°API) e o volume *in situ* é de aproximadamente 130 milhões de m³. A pressão inicial do reservatório é de 327 kgf/cm² e sua pressão de saturação é de 210 kgf/cm². O modelo de fluido é do tipo *Black-Oil*.

O reservatório é dividido em duas regiões (bloco leste e oeste) separados por uma falha do tipo selante, conforme Figura 4.1. A região em vermelho representa o bloco leste e em azul, o bloco oeste.

A estratégia de produção do modelo UNISIM-I-M contém 25 poços (Avansi e Schiozer, 2015), sendo 14 poços produtores, sendo 4 verticais e 10 horizontais (a) e 11 poços injetores horizontais (b).

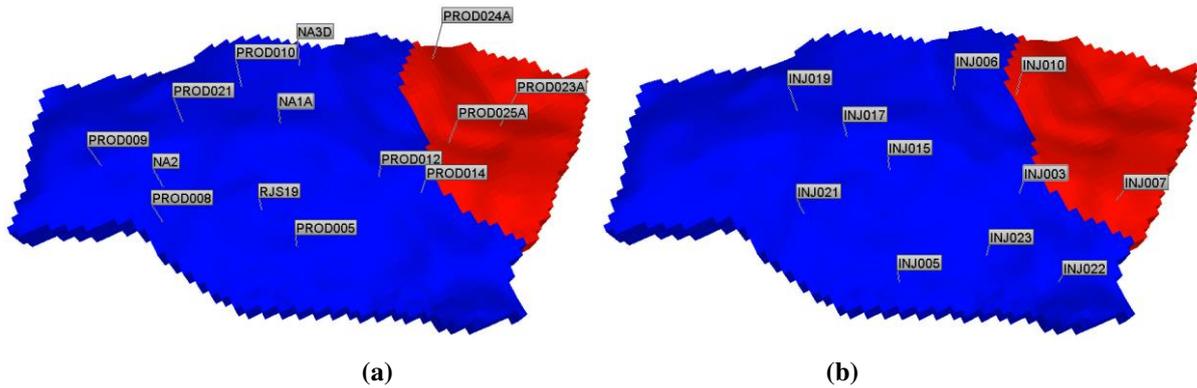


Figura 4.1: Estratégia de produção do modelo UNISIM-I-M, produtores (a) e injetores (b).

O período de histórico de produção inicia-se no tempo 0 e vai até 2618 dias (~7 anos), já o período de previsão vai de 2618 até 10957 dias (~30 anos). O primeiro poço injetor é aberto após 2009 dias (~5 anos e 6 meses), sendo assim, vale a pena destacar que em 2618 dias a frente de água começa a chegar nos poços produtores, tornando o ajuste de histórico mais difícil.

4.2 Incluir Dados Observados

Para iniciar a etapa de inclusão de dados observados foi necessário definir os ciclos com suas respectivas abordagens. Os ciclos são delimitados por um intervalo de tempo de histórico, de acordo com a Tabela 4.1. Foram definidos 6 ciclos, dos quais o Ciclo 1 representa o histórico do UNISIM-I-M com 2618 dias, no Ciclo 2 são acrescentados 18 meses de dados com relação ao ciclo anterior e a partir do Ciclo 3 acrescenta-se 6 meses de dados, chegando até o Ciclo 6 com 4018 dias. O ciclo de 18 meses (diferente dos demais) foi definido para coincidir com a data da sísmica utilizada em outro trabalho do grupo (ainda em andamento), cujo objetivo é utilizar dados de sísmica 4D em um processo de ajuste de histórico por ciclos usando o mesmo caso, mas usando outra metodologia. A ideia é permitir uma posterior comparação.

Tabela 4.1: Intervalos de tempo de histórico dos ciclos sob diferentes abordagens.

Ciclo	Tempo	Abordagem
1	0 até 2618 dias	A
2	0 até 3287 dias	A, B e C
3	0 até 3470 dias	
4	0 até 3652 dias	
5	0 até 3835 dias	
6	0 até 4018 dias	

É importante destacar que no Ciclo 1 não há referência às abordagens B e C, pois não há modelos ajustados para a sua aplicação.

4.3 ES-MDA

4.3.1 Aplicação do ES-MDA

A aplicação do ES-MDA foi realizada através da ferramenta *Ensemble History Matching* (EHM) pertencente à Petrobras e *University of Tulsa* aplicada ao caso UNISIM-I-M.

Inicialmente, foram definidos alguns parâmetros para a aplicação do ES-MDA em todos os ciclos. De acordo com o trabalho de Emerick e Reynolds (2013), o número de assimilações (N_i) foi definido igual 4 e o coeficiente de inflação (α_i) como constante e igual 4. Esses valores de acordo com o trabalho citado são suficientes para atingir bons resultados com relação à qualidade do ajuste.

Para formar o conjunto inicial foi preciso definir o número de modelos (N_e) que compõe o conjunto. A fim de evitar uma redução excessiva da variabilidade do conjunto, definiu-se N_e igual a 500, de acordo com o trabalho de Soares (2017).

Além da definição do número de modelos, foi necessário definir as incertezas e sua parametrização. As incertezas foram divididas em dois grupos, incertezas espaciais e incertezas escalares.

- Incerteza espacial: está relacionada às propriedades definidas em cada bloco do modelo do reservatório, como permeabilidade horizontal nas direções x e y (k_x e k_y), permeabilidade vertical (k_z), porosidade e *net-to-gross* (NTG).
- Incerteza escalar: um único valor é definido para todo o reservatório ou para uma região específica. Cada modelo deve possuir um único valor constante para cada atributo incerto, como contato óleo-água (DWOC) do bloco leste, compressibilidade da rocha (CPOR), multiplicador de permeabilidade vertical (MOD) e permeabilidade relativa da água (k_{rw}).

Assim, foram geradas 500 imagens equiprováveis iniciais por meio de técnicas geoestatísticas, denominadas de incertezas espaciais. A parametrização inicial das incertezas escalares foi definida com base no trabalho de Avansi (2014). Os valores mínimo, máximo e média podem ser observados na Tabela 4.2. Vale a pena destacar que dependendo da abordagem a ser utilizada os valores mínimo e máximo da parametrização dos atributos escalares podem ser alterados ao longo dos ciclos, bem como a sua distribuição de probabilidade.

Para as permeabilidades k_x , k_y e k_z utilizou-se uma transformação logarítmica para aproximar a distribuição desses atributos de uma distribuição do tipo gaussiana (normal), de acordo com a Equação (4.1):

$$k' = \ln(k) \quad (4.1)$$

onde k representa o valor das permeabilidades e k' a permeabilidade transformada.

O valor máximo da permeabilidade vertical (k_z) foi definido como 10% do valor máximo da permeabilidade horizontal, assim como foi feito no trabalho de Soares (2017).

A incerteza da permeabilidade relativa (k_{rw}) foi representada de acordo com a Equação (4.2) (Soares, 2017):

$$k_{rw} = k_{rwiro} \left(\frac{S_w - S_{wcrit}}{1 - S_{wcrit} - S_{orw}} \right)^{P_{krw}} \quad (4.2)$$

sendo k_{rwiro} a máxima permeabilidade relativa da água, S_w a saturação de água, S_{wcrit} a saturação de água crítica, S_{orw} a saturação de óleo residual e P_{krw} é o expoente que determina a forma da curva de k_{rw} . Conforme mostrado na Tabela 4.2, somente o k_{rwiro} e o P_{krw} foram considerados como incertos.

Tabela 4.2: Parametrização original das incertezas espaciais e escalares.

Incertezas		Distribuição	Parametrização		
			Mínimo	Máximo	Média
Escalares	Contato óleo-água (DWOC) (m)	Triangular	3169	3179	3174
	Compressibilidade da Rocha (CPOR) ((kgf/cm ²) ⁻¹)	Triangular	1,00E-05	9,60E-05	5,30E-05
	Multiplicador da Permeabilidade K (MOD)	Triangular	0,01	3,00	1,50
	Expoente de k_{rw} (P_{krw})	Triangular	1,50	3,30	2,3
	Máxima Permeabilidade Relativa da Água (k_{rwiro})	Triangular	0,15	0,52	0,33
Espaciais	Porosidade	-	0	0,31	-
	k_x (mD)	-	1	5000	-
	k_y (mD)	-	1	5000	-
	k_z (mD)	-	1	500	-
	NTG	-	0	1	-

A simulação dos conjuntos de modelos foi realizada pelo software comercial IMEX, do qual foram obtidos os dados de vazão de óleo (q_o), água (q_w) e líquido (q_l) e BHP para os produtores e vazão de água injetada (q_{wi}) e BHP para os injetores. Esses dados simulados (d_{sim}) são incorporados no processo de assimilação de dados do ES-MDA. As variáveis informadas no período de histórico como condições de contorno foram q_l para os produtores e q_{wi} para os injetores.

Para perturbar os dados observados no processo de assimilação de dados foi considerado um desvio padrão que representa o erro de medição, definido como 10% para cada um dos dados a serem assimilados. Os dados assimilados foram q_o , q_w , q_l e BHP para os produtores e q_{wi} e BHP para os injetores.

No processo de assimilação de dados é necessário inverter as matrizes (C_{DD} e C_D). O método utilizado para realizar esta tarefa foi a Inversão do subespaço (*subspace inversion*) com valor de truncamento (baseado nos valores singulares) de 99%, disponível na ferramenta EHM. Maiores detalhes sobre o método podem ser encontrados no trabalho de Emerick (2016).

As incertezas espaciais definidas em cada bloco do reservatório são atualizadas conforme regiões de influência (técnica da localização) baseadas nas linhas de fluxo, de acordo com o trabalho de Soares (2017). As linhas de fluxo são geradas por meio de um modelo que representa a média dos atributos em cada ciclo a priori (antes do ajuste) de acordo com as diferentes abordagens. A definição da região de influência de cada poço é realizada com base na linha de fluxo de maior abrangência, considerando todo o período de histórico (ciclo). A Figura 4.2 ilustra um exemplo da definição das regiões de influência com base nas linhas de fluxo do poço produtor PROD009, onde as linhas em vermelho representam o fluxo da água e do óleo, e a elipse em azul, a região de influência.

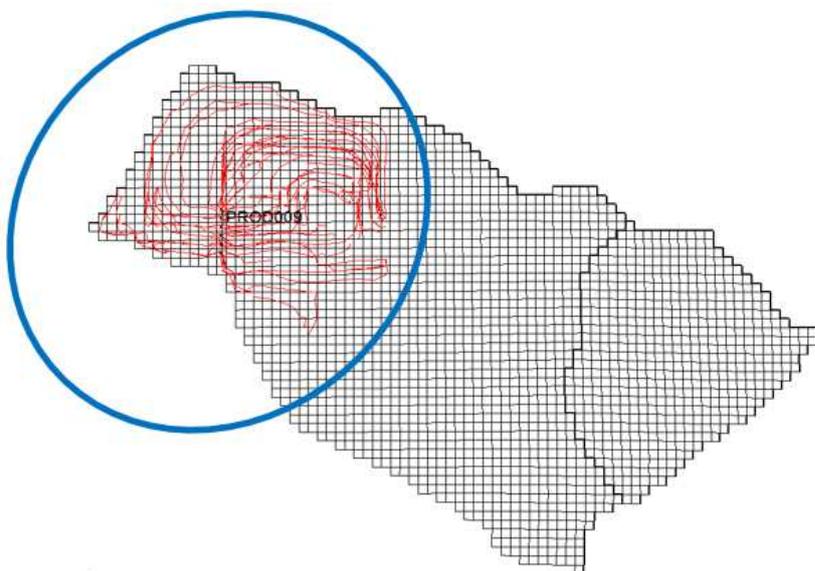


Figura 4.2: Definição da elipse (região de influência) em torno do poço PROD009.

As incertezas escalares não foram atualizadas conforme regiões de influência (técnica da localização), mas, os dados foram assimilados para atualizar esses atributos. Como o DWOC é incerto somente no bloco leste, apenas os dados de produção dos poços (PROD023A,

PROD024A, PROD025A, INJ007 e INJ010) deste bloco foram assimilados para a atualização. Portanto, somente os atributos espaciais são assimilados conforme regiões de influência e todos os atributos incertos foram atualizados respeitando os limites de parametrização.

4.3.2 Análise da qualidade do ajuste

A análise da qualidade do ajuste é realizada por meio do AQNS para todos os ciclos e as variáveis analisadas foram q_o , q_w e BHP dos poços produtores, e q_{wi} e BHP dos poços injetores. As tolerâncias e constantes utilizadas para o cálculo do AQNS se encontram na Tabela 4.3.

Tabela 4.3: Parâmetros utilizados para o cálculo do AQNS.

Variável	Constante (C)	Tolerância (Tol)
q_o	0 m ³ /d	0,1
q_w	20 m ³ /d	0,1
q_{wi}	0 m ³ /d	0,05
BHP	0 kgf/cm ²	0,1

A avaliação da qualidade do ajuste foi realizada antes e após a aplicação do ES-MDA em todos os ciclos, comparando a qualidade do ajuste entre as abordagens em cada ciclo. Por fim, avaliou-se também a qualidade do ajuste por meio da filtragem de modelos para diferentes faixas de aceitação do |AQNS|. Essa análise foi realizada para todos os modelos, considerando as variáveis analisadas separadamente e simultaneamente.

4.3.3 Análise das incertezas

A análise das incertezas é aplicada, primeiramente, no conjunto de modelos a priori do Ciclo 1 e posteriormente no conjunto de modelos atualizados de cada ciclo. Essa análise é realizada para comparar a redução da variabilidade e convergência do método nas diferentes abordagens ao longo dos ciclos.

Para analisar a variabilidade dos atributos escalares, utilizou-se o desvio padrão normalizado com base no resultado a priori do Ciclo 1, de acordo com a Equação (4.3):

$$Desv_N = \frac{Desv (post do ciclo n)}{Desv (a priori do ciclo 1)} \quad (4.3)$$

sendo que $Desv_N$ é o desvio padrão normalizado. Portanto, o desvio padrão normalizado do resultado a priori será 100%, considerando que inicialmente há 100% de variabilidade e o

restante será calculado com base na Equação (4.3) obtendo valores menores que 100%, pois o processo de ajuste de histórico reduz a variabilidade dos atributos.

4.4 Previsão da Produção

A previsão da produção foi realizada, primeiramente, para todos os modelos do conjunto atualizado sem o filtro de cada ciclo. Posteriormente, foi realizada a previsão da produção dos modelos filtrados para todos os ciclos e abordagens. Em todas as previsões, foram utilizadas as mesmas condições operacionais, de acordo com a Tabela 4.4, que são as mesmas condições utilizadas para simular o modelo de referência.

A filtragem de modelos para a previsão foi realizada para todos os modelos com valores de $|AQNS|$ menores ou iguais a 5, considerando todas as variáveis analisadas simultaneamente. Essa filtragem de modelos menos restritiva é importante para evitar a redução excessiva da variabilidade.

Tabela 4.4: Condições operacionais dos poços na etapa de previsão da produção.

Tipo de poço	Condição	Valor
Produtor	Máximo corte de água	0,90
	Máxima Razão Gás-Óleo (RGO)	200 m ³ /m ³
	Mínima qo	20 m ³ /d
	Mínima BHP	190 kgf/cm ²
	Máxima ql	2.000 m ³ /d
Injetor	Máxima BHP	350 kgf/cm ²
	Máxima qwi	5.000 m ³ /d

Após a previsão da produção dos modelos, foi realizada uma comparação da vazão acumulada de óleo (Np) e de água (Wp) para verificar qual das abordagens (A, B e C) apresentam melhores resultados, considerando a resposta real.

5 RESULTADOS E DISCUSSÕES

Conforme descrito na metodologia, a avaliação dos resultados foi dividida em três partes, análise do ajuste, análise das incertezas e previsão da produção. Os resultados serão mostrados abordando todos os ciclos e analisando cada abordagem.

5.1 Análise do ajuste

Os resultados de cada abordagem foram analisados por meio da filtragem de modelos com base no $|AQNS|$. Esta análise foi realizada para cada variável analisada (q_o , q_w , q_{wi} e BHP dos poços produtores e injetores) e para todas as variáveis simultaneamente (Total).

A Tabela 5.1 mostra a porcentagem de modelos filtrados das abordagens A, B e C, com base no $|AQNS|$ menor ou igual a 3.

No (A1)pr1, não há modelos ajustados, pois trata-se do conjunto de modelos a priori, antes do ajuste de histórico. Por este motivo, somente 2% dos modelos foram filtrados para q_o e para o restante das variáveis, 0%. Após o ajuste, a pouca quantidade de informações foi o fator limitante da qualidade do (A1)pt1, à exceção da q_o com 100%. Para q_w , 31.2% dos modelos foram filtrados. Quanto ao Total, somente 3,2%.

A partir do Ciclo 2, as três abordagens serão comparadas em conjunto. Primeiramente, será realizada a análise do resultado a priori de um determinado ciclo para cada abordagem. Conforme descrito na metodologia, esta análise é realizada para verificar se os modelos ajustados de um determinado ciclo (n) preservam a mesma qualidade do ajuste ao incorporar os dados até o ciclo seguinte (n+1). Em seguida, realiza-se a análise do ajuste de histórico de um determinado ciclo. Nesta análise, verifica-se como ficou o ajuste para cada variável analisada em comparação com o resultado a priori do mesmo ciclo.

No Ciclo 2 (antes do ajuste), ao incluir novos dados é possível notar que a qualidade do ajuste foi reduzida, principalmente para o BHP e q_w . Em outras palavras, os modelos não preservaram a mesma qualidade do ajuste ao incorporar os dados até o Ciclo 2, devido à baixa qualidade do (A1)pt1. Por exemplo, no (A2)pr2, 0% de modelos foram filtrados para q_w e para o Total. Como ainda não foi realizado o ajuste sob diferentes abordagens (A, B e C), os resultados (A2)pr2, (B2)pr2 e (C2)pr2 são iguais.

No Ciclo 2 (após o ajuste), notou-se que a qualidade do ajuste dos dados melhorou para todas as variáveis nas três abordagens. A única exceção foi a q_{wi} na Abordagem A que sofreu pequena redução da qualidade. Vale a pena destacar que a disponibilidade de novas

informações, aliada ao tipo de abordagem, melhorou consideravelmente a qualidade do ajuste nas abordagens B e C em comparação com a Abordagem A.

Como exemplo, entre o (A2)pr2 e o (A2)pt2, a porcentagem de modelos da q_w aumentou de 0% para 29,8%. No entanto, nas abordagens B e C esse aumento foi muito maior. Entre o (B2)pr2 e o (B2)pt2, essa porcentagem de modelos aumentou de 0% para 58,6%. Entre o (C2)pr2 e o (C2)pt2, aumentou de 0% para 42,4%. Quanto ao Total, no (A2)pt2 somente 17% dos modelos foram filtrados, devido à baixa qualidade do ajuste da q_w . Enquanto que no (B2)pt2, 43,4% e no (C2)pt2, 38%.

No Ciclo 3 (antes do ajuste), a qualidade do ajuste reduziu muito pouco para todas as variáveis das três abordagens, no entanto, essa redução foi mais significativa na Abordagem A. Pela primeira vez, nas três abordagens, os modelos preservaram o ajuste ao adicionar os dados até o Ciclo 3, embora a qualidade do ajuste da Abordagem A seja menor em comparação com as outras abordagens. Esta melhoria nos resultados está relacionada com a qualidade do ajuste do Ciclo 2. Geralmente, os modelos que possuem uma melhor qualidade de ajuste tendem a preservá-la ao adicionar um novo dado.

Por exemplo, no (A3)pr3, 21,6% dos modelos foram filtrados para q_w . No entanto, nas abordagens B e C esse número foi maior, com 51,2% no (B3)pr3, e 38% no (C3)pr3. Quanto ao Total, somente 9,6% dos modelos foram filtrados no (A3)pr3, em contrapartida, 40,2% dos modelos foram filtrados no (B3)pr3 e 30,4% no (C3)pr3.

No Ciclo 3 (após o ajuste), novamente a qualidade do resultado melhorou nas abordagens B e C. No entanto, na Abordagem A, constatou-se uma certa dificuldade do método em ajustar a q_w e q_o , mesmo com uma maior quantidade de dados observados. Além disso, a redução da qualidade do ajuste da q_w ocasionou a redução da qualidade do Total.

Como exemplo, entre o (A3)pr3 e (A3)pt3, a qualidade do ajuste da q_w praticamente não se alterou, aumentando de 0% para 0,4%. Devido a este motivo, a q_o acabou reduzindo de 63% para 57,8%. Nas abordagens B e C, a porcentagem aumentou significativamente. Entre o (B3)pr3 e (B3)pt3, aumentou de 51,2% para 91,6%. E entre o (C3)pr3 e o (C3)pt3, de 38% para 87,2%. Quanto ao Total, 0,4% dos modelos foram filtrados no (A3)pt3, 87,2% no (B3)pt3 e 85,4% no (C3)pt3.

No Ciclo 4 (antes do ajuste), a qualidade dos dados também reduziu muito pouco nas três abordagens, à exceção da q_{wi} . Vale a pena destacar que na Abordagem A o ajuste da q_w e do Total no ciclo anterior apresentava uma qualidade muito baixa e por isso não havia como a reduzir ainda mais ao incorporar novos dados. Por exemplo, no (A4)pr4, a porcentagem da q_w se manteve em 0%. Nas outras abordagens, os modelos preservaram o ajuste, com 75% no

(B4)pr4, e 56% no (C4)pr4. Quanto ao Total, 0% no (A4)pr4, 73% no (B4)pr4 e 55% no (C4)pr4.

No Ciclo 4 (após o ajuste), da mesma forma que nos ciclos anteriores, a qualidade do ajuste melhorou nas abordagens B e C. No entanto, a q_w continuou sendo a variável com a pior qualidade de ajuste na Abordagem A, impactando a qualidade do Total. Neste ciclo, novamente o método mesmo com uma maior quantidade de dados enfrentou dificuldades para ajustar a q_w e q_o . Além disso, na Abordagem B foi necessário reparametrizar alguns atributos, discutidos na seção 5.2. Como exemplo, entre o (A4)pr4 e o (A4)pt4, a qualidade do ajuste da q_w aumentou de 0% para 0,2%. Quanto ao Total, 0% no (A4)pt4, 95,2% no (B4)pt4.1, e 92,2% no (C4)pt4.

No Ciclo 5 (antes do ajuste), da mesma forma que nos ciclos anteriores, a qualidade do ajuste nas abordagens B e C reduziu pouco. No entanto, a qualidade do ajuste na Abordagem A continuou baixa para q_w e o Total, pois até o ajuste do Ciclo 4, o método não conseguiu ajustar a q_w de forma satisfatória. Por exemplo, no (A5)pr5 novamente nenhum modelo passou pelo critério de filtro para q_w , enquanto que no (B5)pr5 44,8% e no (C5)pr5 56,2%. Quanto ao Total, 0% no (A5)pr5, 44,8% no (B5)pr5 e 54,8% no (C5)pr5.

No Ciclo 5 (após o ajuste), o método melhorou a qualidade do ajuste para todas as variáveis nas três abordagens. Na Abordagem A, a melhoria na qualidade do ajuste da q_w possibilitou melhorar a qualidade do Total. Na Abordagem B, também foi necessário reparametrizar alguns atributos. Como exemplo, entre o (A5)pr5 e (A5)pt5, a qualidade da q_w aumentou de 0% para 11,2%. Quanto ao Total, 7,8% foram filtrados no (A5)pr5, 95,8% no (B5)pt5.1 e 92,2% no (C5)pt5.

No Ciclo 6 (antes do ajuste), a incorporação de novos dados reduziu pouco a qualidade do ajuste nas três abordagens. No entanto, na Abordagem A, pela segunda vez os modelos ajustados começam a preservar a qualidade do ajuste ao incorporar os dados até o Ciclo 6. É importante destacar que o aumento na qualidade do ajuste da q_w foi o principal fator do aumento da porcentagem do Total. Por exemplo, no (A6)pr6, 19% dos modelos foram filtrados para q_w , enquanto que nas abordagens B e C, 93,4% no (B6)pr6 e 91,6% no (C6)pr6. Quanto ao Total, 7% no (A6)pr6, 93,2% no (B6)pr6 e 90,8% no (C6)pr6.

No Ciclo 6 (após o ajuste), o método melhorou a qualidade do ajuste para todas as variáveis. Sendo que na Abordagem A, a q_w melhorou ainda mais a qualidade, aumentando a porcentagem de modelos filtrados do Total. No entanto, nas abordagens B e C, a qualidade continuou sendo muito superior à Abordagem A. Como exemplo, 33,6% de modelos foram filtrados para q_w no (A6)pt6, 97,8% no (B6)pt6.1 e 94% no (C6)pt6. Quanto ao Total, 24,8% no (A6)pt6, 97,6% no (B6)pt6.1 e 93,6% no (C6)pt6.

Tabela 5.1: Porcentagens de modelos filtrados em todos os ciclos nas abordagens A, B e C.

AQNS	Ciclo	q _o	q _w	q _{wi}	BHP	Total
3	(A1)pr1	2	0	0	0	0
	(A1)pt1	100	31,2	36,6	26,8	3,2
	(A2)pr2	86,4	0	60,2	5,4	0
	(A2)pt2	99,4	29,8	58,2	99,2	17
	(A3)pr3	99,2	21,6	62,2	77,4	9,6
	(A3)pt3	57,8	0,4	81	98,6	0,4
	(A4)pr4	44,2	0	82	93	0
	(A4)pt4	65	0,2	57,6	98,8	0
	(A5)pr5	59	0	59,6	93,2	0
	(A5)pt5	87,6	11,2	69,2	93,6	7,8
	(A6)pr6	83,8	19	71,2	63,8	7
	(A6)pt6	90,4	33,6	75	99,4	24,8
	(B2)pr2	86,4	0	60,2	5,4	0
	(B2)pt2	100	58,6	75	100	43,4
	(B3)pr3	100	51,2	79,2	99,6	40,2
	(B3)pt3	100	91,6	94,2	100	87,2
	(B4)pr4	100	75	95,2	100	73
	(B4)pt4.1	100	95,2	100	100	95,2
	(B5)pr5	100	44,8	100	100	44,8
	(B5)pt5.1	100	96,2	99,6	100	95,8
	(B6)pr6	100	93,4	99,8	100	93,2
	(B6)pt6.1	100	97,8	99,8	100	97,6
	(C2)pr2	86,4	0	60,2	5,4	0
	(C2)pt2	100	48,2	81,4	100	38
	(C3)pr3	99,8	38	83	99,8	30,4
	(C3)pt3	100	87,2	98,2	100	85,4
	(C4)pr4	100	56	98,6	100	55
	(C4)pt4	100	95	96,8	100	92,2
	(C5)pr5	100	56,2	97,4	100	54,8
	(C5)pt5	100	93	99,2	100	92,2
(C6)pr6	100	91,6	99,2	100	90,8	
(C6)pt6	100	94	99,6	100	93,6	

A Figura 5.1 mostra o número de modelos em função do |AQNS| para o Total das abordagens A, B e C, do resultado a priori e a posteriori. Para cada valor de |AQNS| (eixo x), o valor correspondente no eixo y indica o número de modelos para os quais todas as FO (Total) encontram-se dentro do valor estabelecido com base no |AQNS|.

Como foi descrito anteriormente, devido à baixa qualidade de ajuste, observa-se uma dificuldade dos modelos ajustados em preservar a mesma qualidade de ajuste após a inclusão

de novos dados em cada ciclo da Abordagem A (Figura 5.1a). Somente no (A3)pr3 e (A6)pr6, os modelos começam a preservar a qualidade do ajuste dos dados. Para o |AQNS| menor ou igual a 3, aproximadamente 48 e 35 modelos foram filtrados no (A3)pr3 e (A6)pr6, respectivamente. No entanto, para o |AQNS| menor ou igual a 1, nenhum modelo foi filtrado.

No (A4)pr4 e (A5)pr5, os modelos aparentam preservar a qualidade do ajuste, no entanto, apenas para o |AQNS| maior ou igual a 5. Salienta-se que essa qualidade do ajuste é inferior em comparação com o |AQNS| menor ou igual a 3.

Analisando a Abordagem B (Figura 5.1c), observa-se que os modelos mantêm o ajuste dos dados a partir do (B3)pr3, confirmando a análise feita anteriormente. Para o |AQNS| menor ou igual a 3, é possível observar nitidamente que entre o (B4)pr4 e o (B5)pr5 há uma redução da qualidade do ajuste. E no (B6)pr6, a qualidade do ajuste dos dados aumenta consideravelmente. Para o |AQNS| menor ou igual a 1, aproximadamente 140 modelos foram filtrados.

Na abordagem C (Figura 5.1e), da mesma forma que na Abordagem B, os modelos mantêm o ajuste dos dados a partir do (C3)pr3. Além disso, quanto maior a quantidade de dados, maior a qualidade do resultado a priori. Por exemplo, no (C6)pr6 a qualidade do ajuste aumenta consideravelmente. Para o |AQNS| menor ou igual a 1, aproximadamente 150 modelos foram filtrados.

Portanto, o método foi capaz de ajustar os modelos em cada ciclo a posteriori em comparação com a incorporação de novas informações em cada ciclo a priori, nas três abordagens. No entanto, a maior quantidade de dados observados pode dificultar o ajuste em alguns ciclos, como foi observado no (A3)pt3 e (A4)pt4 (Figura 5.1b). Apesar do método ajustar os modelos, poucos foram filtrados para o |AQNS| menor ou igual a 3, e nenhum modelo passou pelo |AQNS| menor ou igual a 1.

Vale a pena destacar que a maior quantidade de dados observados contribuiu para melhorar a qualidade do ajuste dos dados nas abordagens B e C (Figura 5.1d e Figura 5.1f). Para o |AQNS| menor ou igual a 1, no (B3)pt3 40 modelos foram filtrados, no (B4)pt4.1, 144 modelos, no (B5)pt5, 198 modelos, e no (B6)pt6, 137 modelos. No (C3)pt3 e (C4)pt4, aproximadamente 70 modelos foram filtrados, no (C5)pt5, 170 modelos e no (C6)pt6, 270 modelos foram filtrados para |AQNS| menor ou igual a 1.

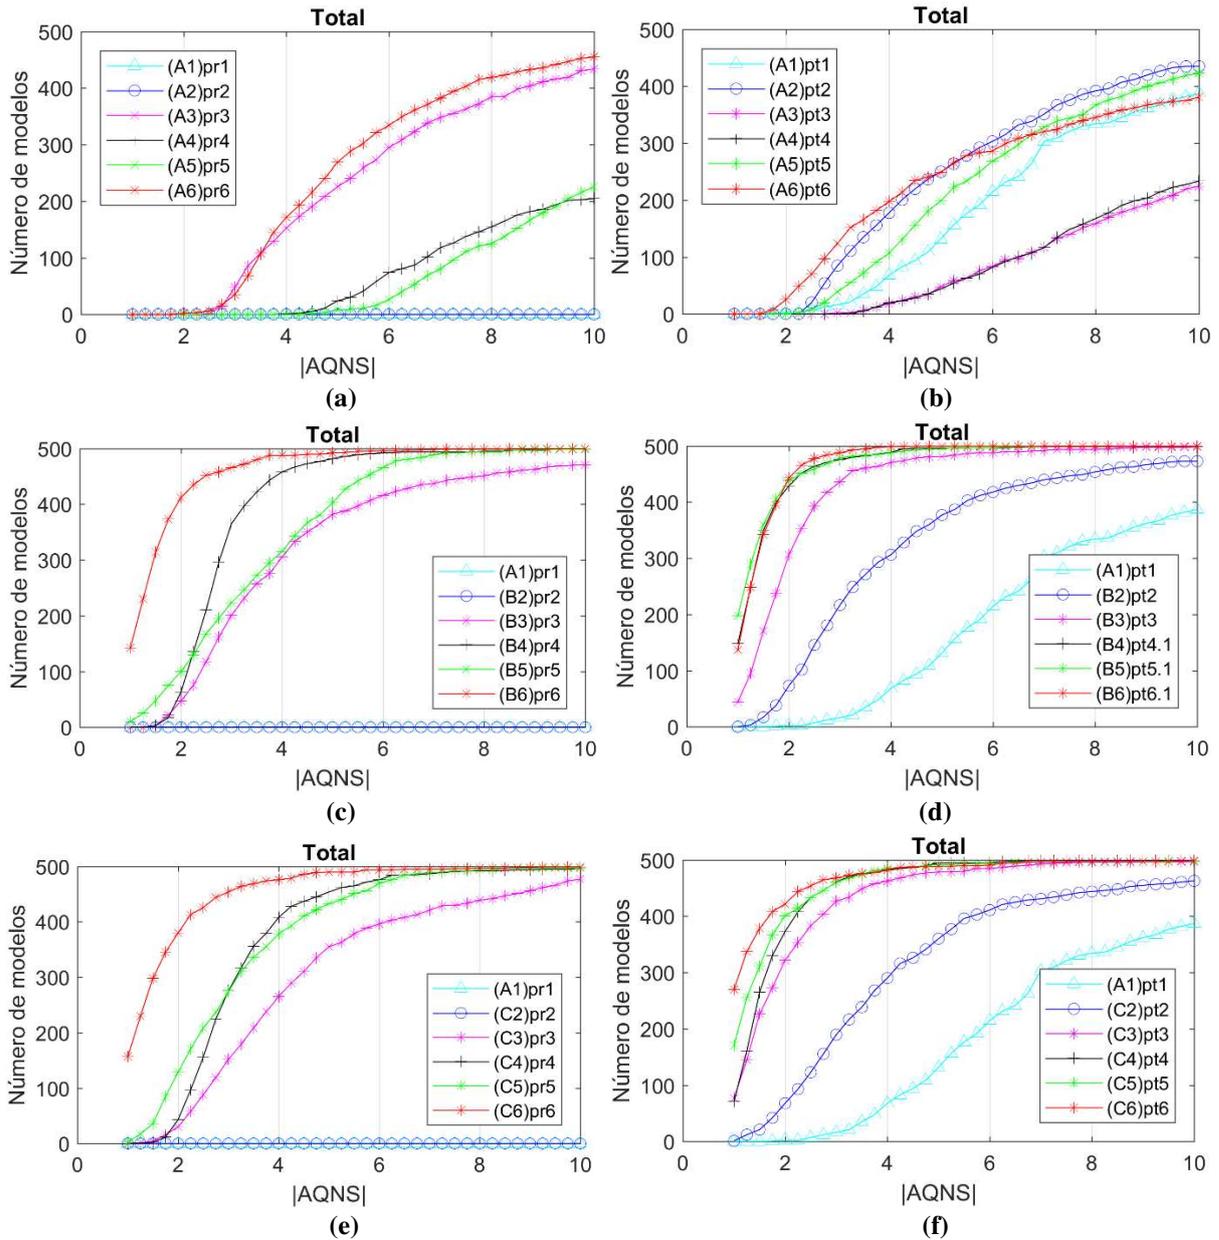


Figura 5.1: Filtragem de modelos para o Total das abordagens A, B e C com base no |AQNS|: (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.

A Figura 5.2 mostra a filtragem de modelos para q_w das abordagens A, B e C com base no |AQNS|, do resultado a priori e a posteriori. Conforme dito anteriormente, uma das causas da baixa qualidade do ajuste do Total na Abordagem A é a qualidade do ajuste da q_w . Esta variável é um fator limitante da filtragem de modelos para o Total, devido à dificuldade em ajustá-la, principalmente com uma maior quantidade de dados. Analisando a Figura 5.2, observou-se que o comportamento da filtragem de modelos da q_w é semelhante ao Total. Para o resultado a posteriori, no (A3)pt3 e (A4)pt4, ocorreu uma redução na qualidade do ajuste (Figura 5.2b). Quanto ao resultado a priori, no (A3)pr3 e (A6)pr6 os modelos começaram a preservar o ajuste dos dados (Figura 5.2a).

Para as abordagens B e C, confirmou-se que o comportamento da filtragem de modelos da q_w também é semelhante ao Total. Para o resultado a posteriori a qualidade do ajuste aumenta consideravelmente a partir do Ciclo 2 nas duas abordagens, (B2)pt2 e (C2)pt2 (Figura 5.2d e Figura 5.2f). Com relação ao resultado a priori da Abordagem B, os modelos começam a preservar o ajuste a partir do (B3)pr3, no entanto, entre o (B4)pr4 e (B5)pr5 ocorreu uma redução na qualidade do ajuste e no (B6)pr6 a qualidade do ajuste aumentou novamente (Figura 5.2c). Na abordagem C, a partir do (C3)pr3 os modelos começam a preservar a qualidade do ajuste dos dados (Figura 5.2e). Os resultados referentes às outras variáveis analisadas (q_o , q_{wi} e BHP dos produtores e injetores) se encontram no Apêndice A.

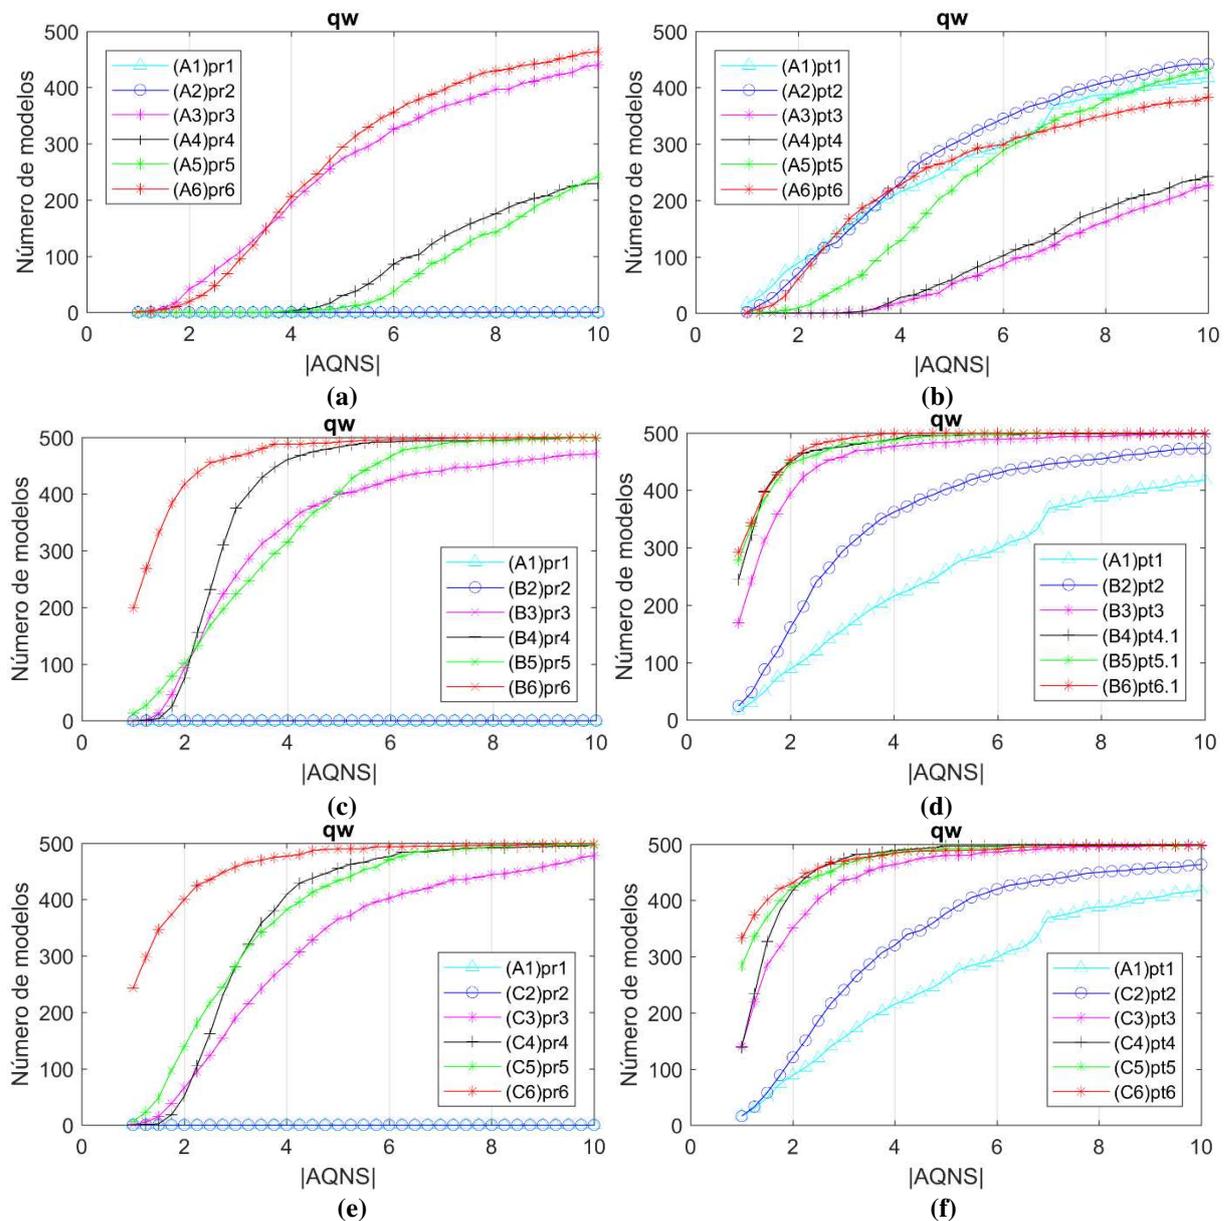


Figura 5.2: Filtragem de modelos para a q_w das abordagens A, B e C com base no $|AQNS|$: (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.

A Figura 5.3 mostra o gráfico de AQNS do resultado a priori e a posteriori da q_w para a Abordagem A. As linhas horizontais indicam a faixa de aceitação $[-3, +3]$. Comparando o resultado a priori (Figura 5.3a) com o a posteriori (Figura 5.3b), observa-se que a qualidade do ajuste melhorou. Em outras palavras, o método reduziu a variabilidade do AQNS em praticamente todos os ciclos avaliando cada poço produtor. No entanto, em alguns poços, boa parte dos modelos encontram-se fora da faixa de aceitação com elevados valores de AQNS em alguns ciclos.

Apesar do método ajustar globalmente os modelos, a qualidade do ajuste não foi preservada para todos os poços ao adicionar um novo dado. Tomando como exemplo o PROD005, no (A3)pt3, apesar de boa parte dos modelos se encontrarem fora da faixa de aceitação (Figura 5.3b), ao adicionar novos dados, os modelos não preservam a mesma qualidade do ajuste no (A4)pt4, aumentando ainda mais a variabilidade do AQNS (Figura 5.3a). Em outro exemplo, no PROD024A, boa parte dos modelos se encontra fora da faixa de aceitação no (A4)pt4. E ao adicionar um novo dado, a variabilidade do AQNS aumenta mais ainda no (A5)pt5.

Quanto ao ajuste dos dados (Figura 5.3a), no (A1)pt1, a menor quantidade de dados observados tornou o ajuste mais fácil para todos os poços, à exceção do PROD010 e PROD014. De forma geral, observa-se boa parte dos modelos dentro da faixa de aceitação. No entanto, o aumento da quantidade de dados observados começa a dificultar o ajuste. Por exemplo, nos poços PROD008, PROD021 e PROD024A boa parte dos modelos encontram-se fora da faixa de aceitação.

Da mesma forma que foi descrito na análise da filtragem de modelos, contata-se uma grande redução na qualidade do ajuste no (A3)pt3 e (A4)pt4. No (A3)pt3, além dos poços do (A2)pt2, outros poços apresentaram boa parte dos modelos fora da faixa, como o PROD005, PROD009, PROD010 e PROD023A. No (A4)pt4, os mesmos poços de (A3)pt3 apresentaram boa parte dos modelos fora da faixa, limitando também a filtragem de modelos.

Por fim, a qualidade do ajuste dos dados começa a melhorar com o aumento da quantidade de dados observados no (A5)pt5. Apesar da melhor qualidade do ajuste em comparação com (A4)pt4, ainda há boa parte dos modelos fora da faixa, por exemplo, nos poços PROD021 e PROD023A. Por isso a filtragem de modelos acaba sendo impactada. No (A6)pt6, o ajuste melhorou em comparação com (A5)pt5. No entanto, o PROD021 e PROD023A apresentou boa parte dos modelos fora da faixa, impactando a filtragem de modelos. Os gráficos de AQNS

referentes às outras variáveis analisadas da Abordagem A (q_o , q_{wi} e BHP dos produtores e injetores) se encontram no Apêndice B.

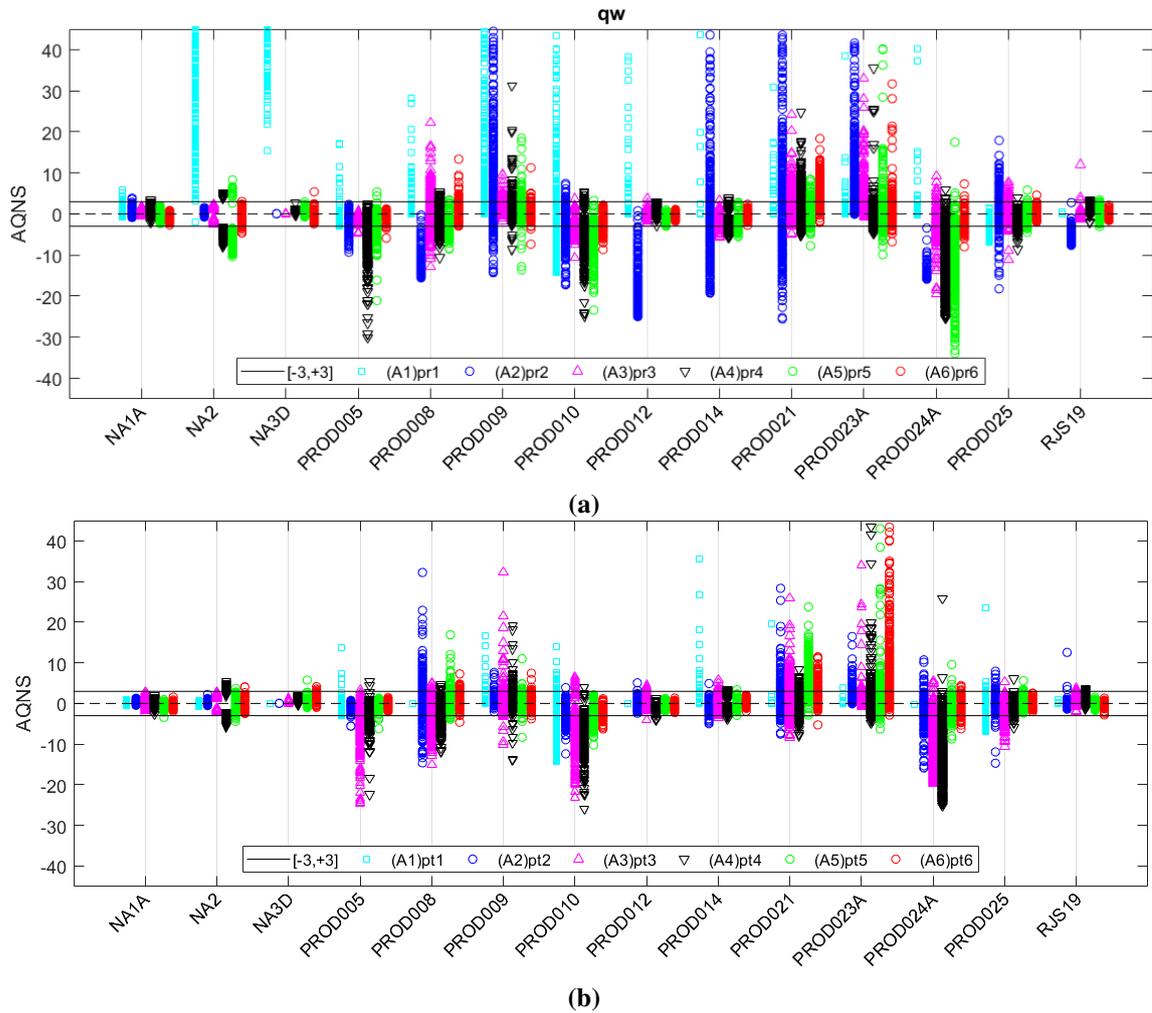


Figura 5.3: AQNS de q_w dos produtores da Abordagem A: a priori (a) e a posteriori (b).

A Figura 5.4 mostra as curvas de produção de água do PROD005 em todos os ciclos a priori e a posteriori da Abordagem A, exemplificando a evolução do ajuste descrita anteriormente.

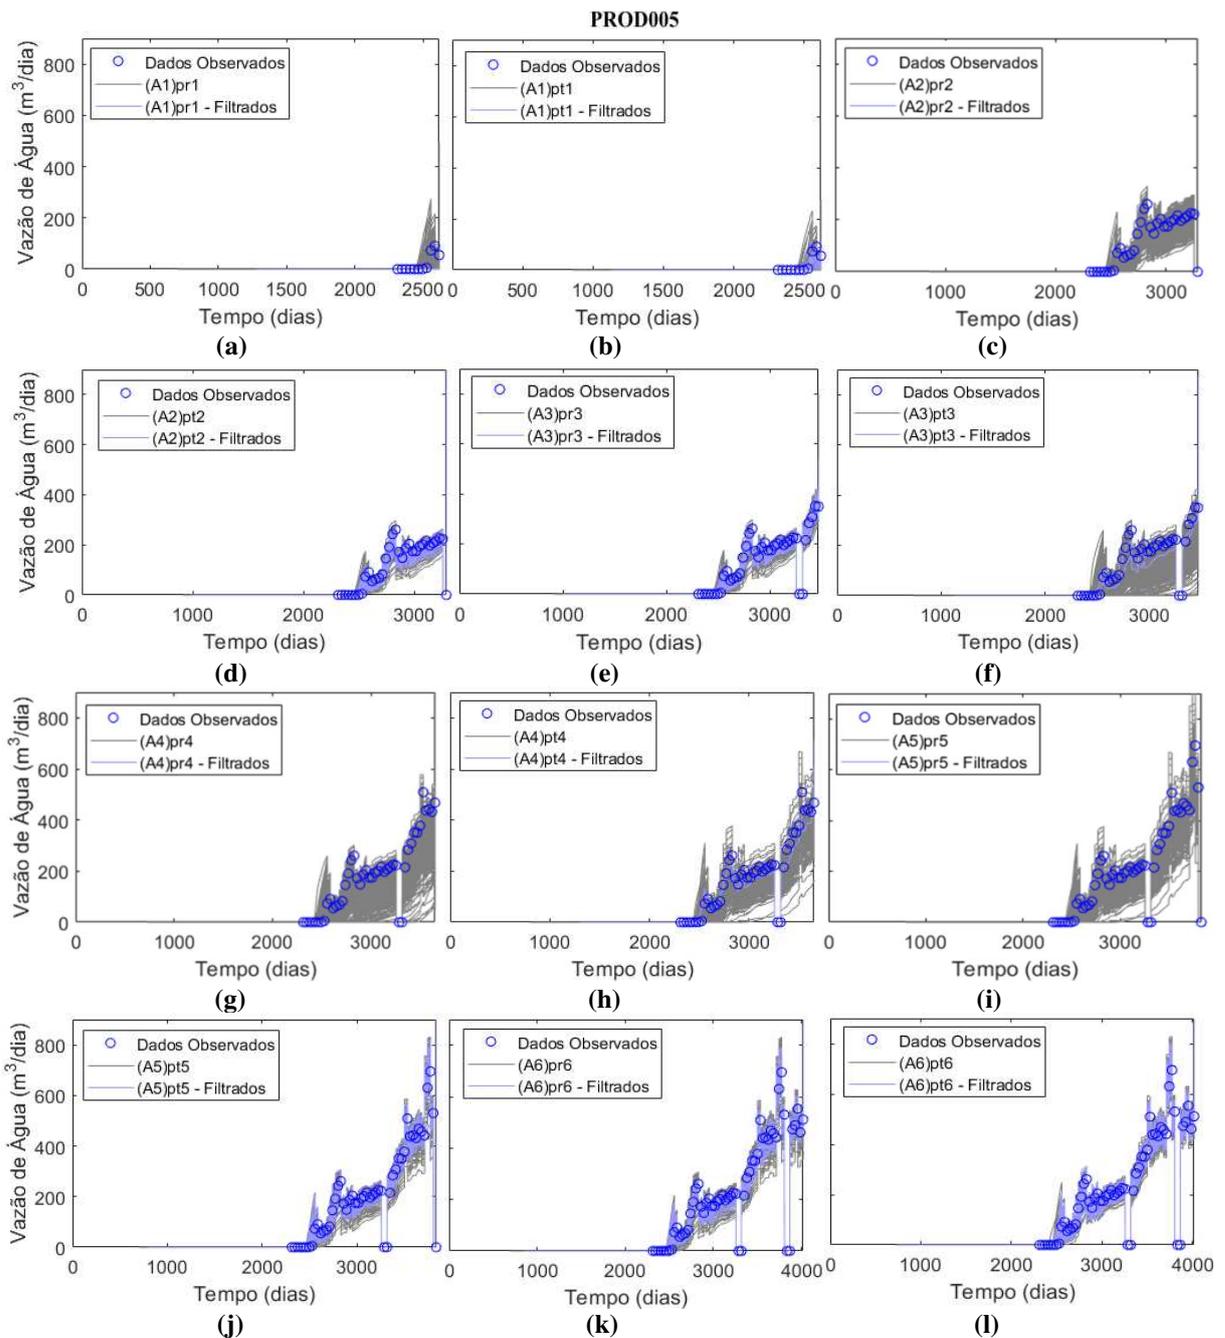


Figura 5.4: Curva de produção de água do poço produtor PROD005 mostrando o ajuste ao longo dos ciclos da abordagem A: (a) (A1)pr1; (b) (A1)pt1; (c) (A2)pr2; (d) (A2)pt2; (e) (A3)pr3; (f) (A3)pt3; (g) (A4)pr4; (h) (A4)pt4; (i) (A5)pr5; (j) (A5)pt5; (k) (A6)pr6 e (l) (A6)pt6.

A Figura 5.5 mostra o gráfico de AQNS do resultado a priori e a posteriori da q_w para a Abordagem B. As linhas horizontais indicam a faixa de aceitação $[-3, +3]$. Comparando o resultado a priori (Figura 5.5a) com o a posteriori (Figura 5.5b), observa-se que o método melhorou a qualidade do ajuste em praticamente todos os ciclos avaliando cada poço produtor.

Com relação ao resultado a posteriori, a qualidade do ajuste tende a aumentar com a quantidade de dados observados. No (B2)pt2, a qualidade do ajuste melhorou em comparação

com (A1)pt1. No entanto, alguns poços ainda apresentam boa parte dos modelos fora da faixa de aceitação $[-3,+3]$, como o PROD008, PROD021 e PROD024A. A partir do (B3)pt3, a maior parte dos modelos encontra-se dentro da faixa de aceitação para todos os poços. Vale a pena destacar que a partir do Ciclo 3, o método consegue ajustar as FOs com melhor qualidade do que na Abordagem A (Figura 5.3).

Por fim, no (B3)pr3, o ajuste dos modelos do (B2)pt2 foi suficiente para preservar a qualidade do ajuste ao adicionar um novo dado. No entanto, embora no PROD008, PROD023A e PROD024A os modelos tenham mantido a qualidade do ajuste, parte dos modelos no (B3)pr3 encontram-se fora da faixa de aceitação. Este comportamento pode ser explicado pelo fato de que no (B2)pt2, parte dos modelos já se encontravam fora da faixa de aceitação nos poços citados. E, ao adicionar os dados, a variabilidade do AQNS se alterou muito pouco. Os gráficos de AQNS referentes às outras variáveis analisadas da Abordagem B (q_o , q_{wi} e BHP dos produtores e injetores) se encontram no Apêndice B.

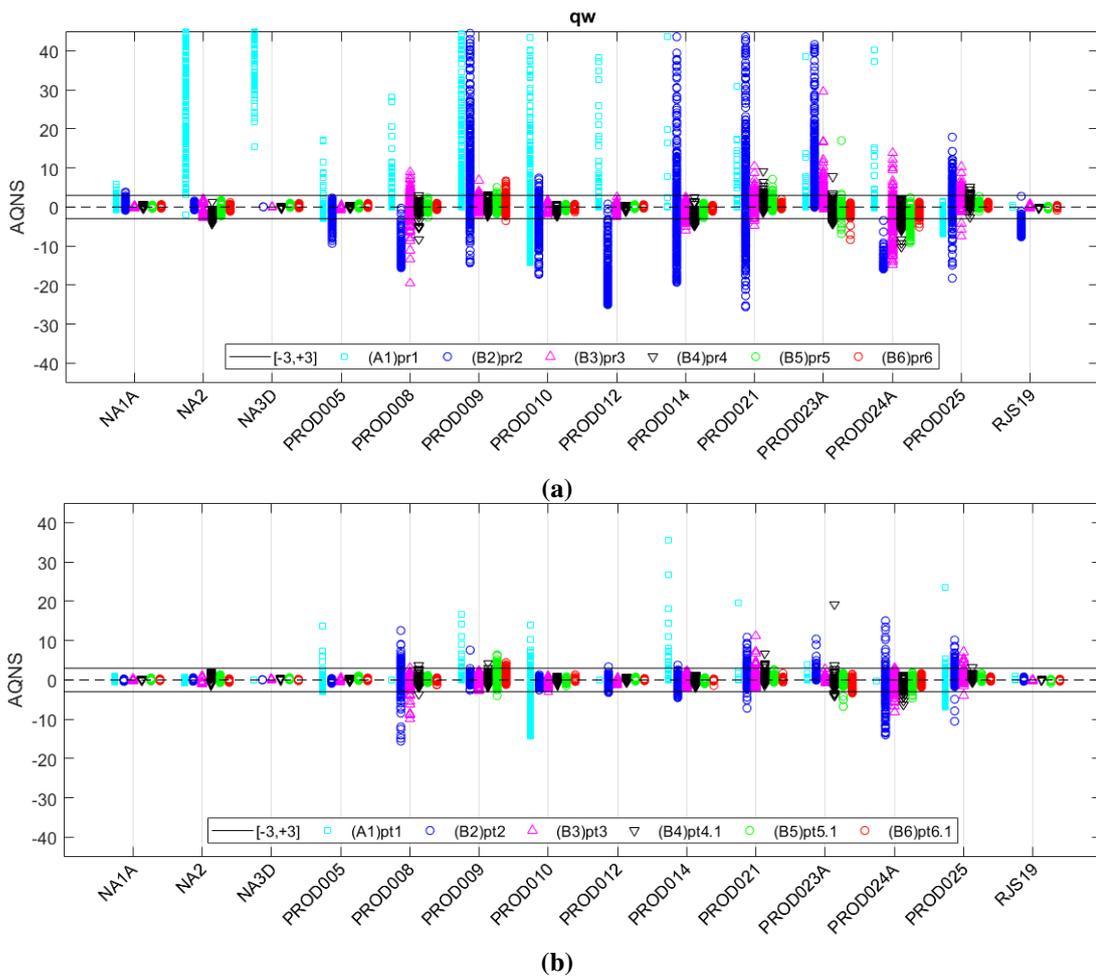


Figura 5.5: AQNS de q_w dos produtores da Abordagem B: a priori (a) e a posteriori (b).

A Figura 5.6 mostra as curvas de produção de água do PROD005 em todos os ciclos a priori e a posteriori da Abordagem B, exemplificando a evolução do ajuste descrita anteriormente.

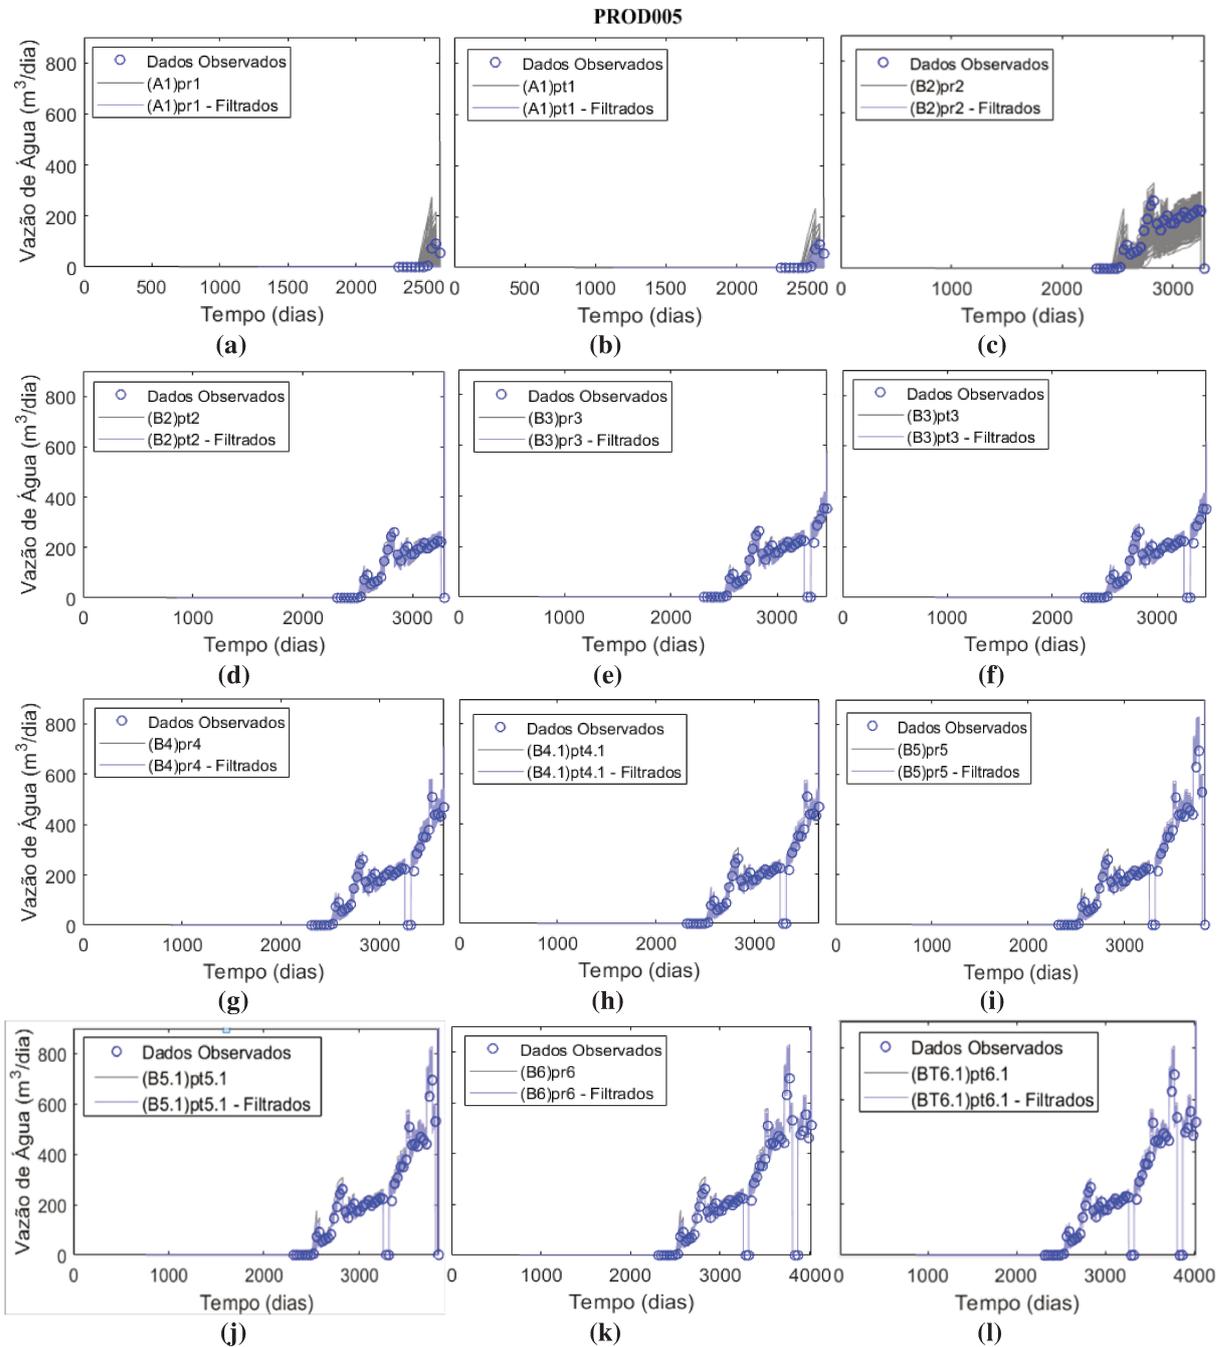


Figura 5.6: Curva de produção de água do poço produtor PROD005 mostrando o ajuste ao longo dos ciclos da abordagem B: (a) (A1)pr1; (b) (A1)pt1; (c) (B2)pr2; (d) (B2)pt2; (e) (B3)pr3; (f) (B3)pt3; (g) (B4)pr4; (h) (B4)pt4; (i) (B5)pr5; (j) (B5)pt5; (k) (B6)pr6 e (l) (B6)pt6.

A Figura 5.7 mostra o gráfico de AQNS do resultado a priori e a posteriori da q_w para a Abordagem C. As linhas horizontais indicam a faixa de aceitação $[-3, +3]$. Comparando o

resultado a priori (a) com o a posteriori (b), observa-se que o método melhorou a qualidade do ajuste em praticamente todos os ciclos avaliando cada poço produtor.

Com relação ao resultado a posteriori, a qualidade do ajuste tende a aumentar com a quantidade de dados observados. No (C2)pt2, a qualidade do ajuste melhorou em comparação com (A1)pt1. No entanto, alguns poços ainda apresentam boa parte dos modelos fora da faixa de aceitação $[-3,+3]$, como o PROD008, PROD09, PROD021 e PROD024A. A partir do (C3)pt3, a maior parte dos modelos encontra-se dentro da faixa de aceitação para todos os poços.

Da mesma forma que na Abordagem B, a partir do Ciclo 3, o método consegue ajustar as FOs com melhor qualidade do que na Abordagem A (Figura 5.3); embora no PROD008, PROD023A e PROD024A os modelos tenham mantido a qualidade do ajuste, parte dos modelos no (C3)pr3 encontra-se fora da faixa de aceitação. Nos outros ciclos, a maior parte dos modelos encontra-se dentro da faixa de aceitação. Outros gráficos de AQNS referentes à Abordagem C (q_o , q_{wi} e BHP dos produtores e injetores) se encontram no Apêndice B.

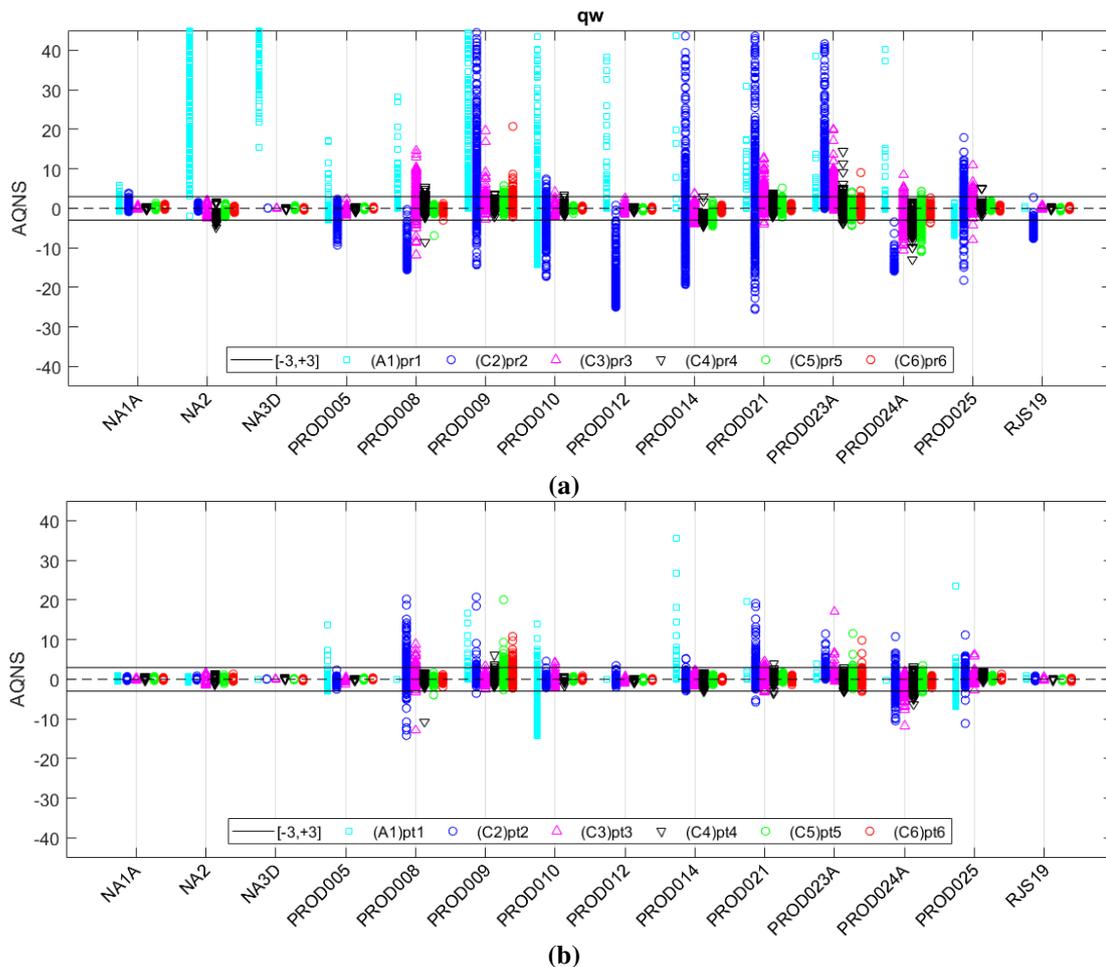


Figura 5.7: AQNS de q_w dos produtores da Abordagem C: a priori (a) e a posteriori (b).

A Figura 5.8 mostra as curvas de produção de água do PROD005 em todos os ciclos a priori e a posteriori da Abordagem C, exemplificando a evolução do ajuste descrita anteriormente.

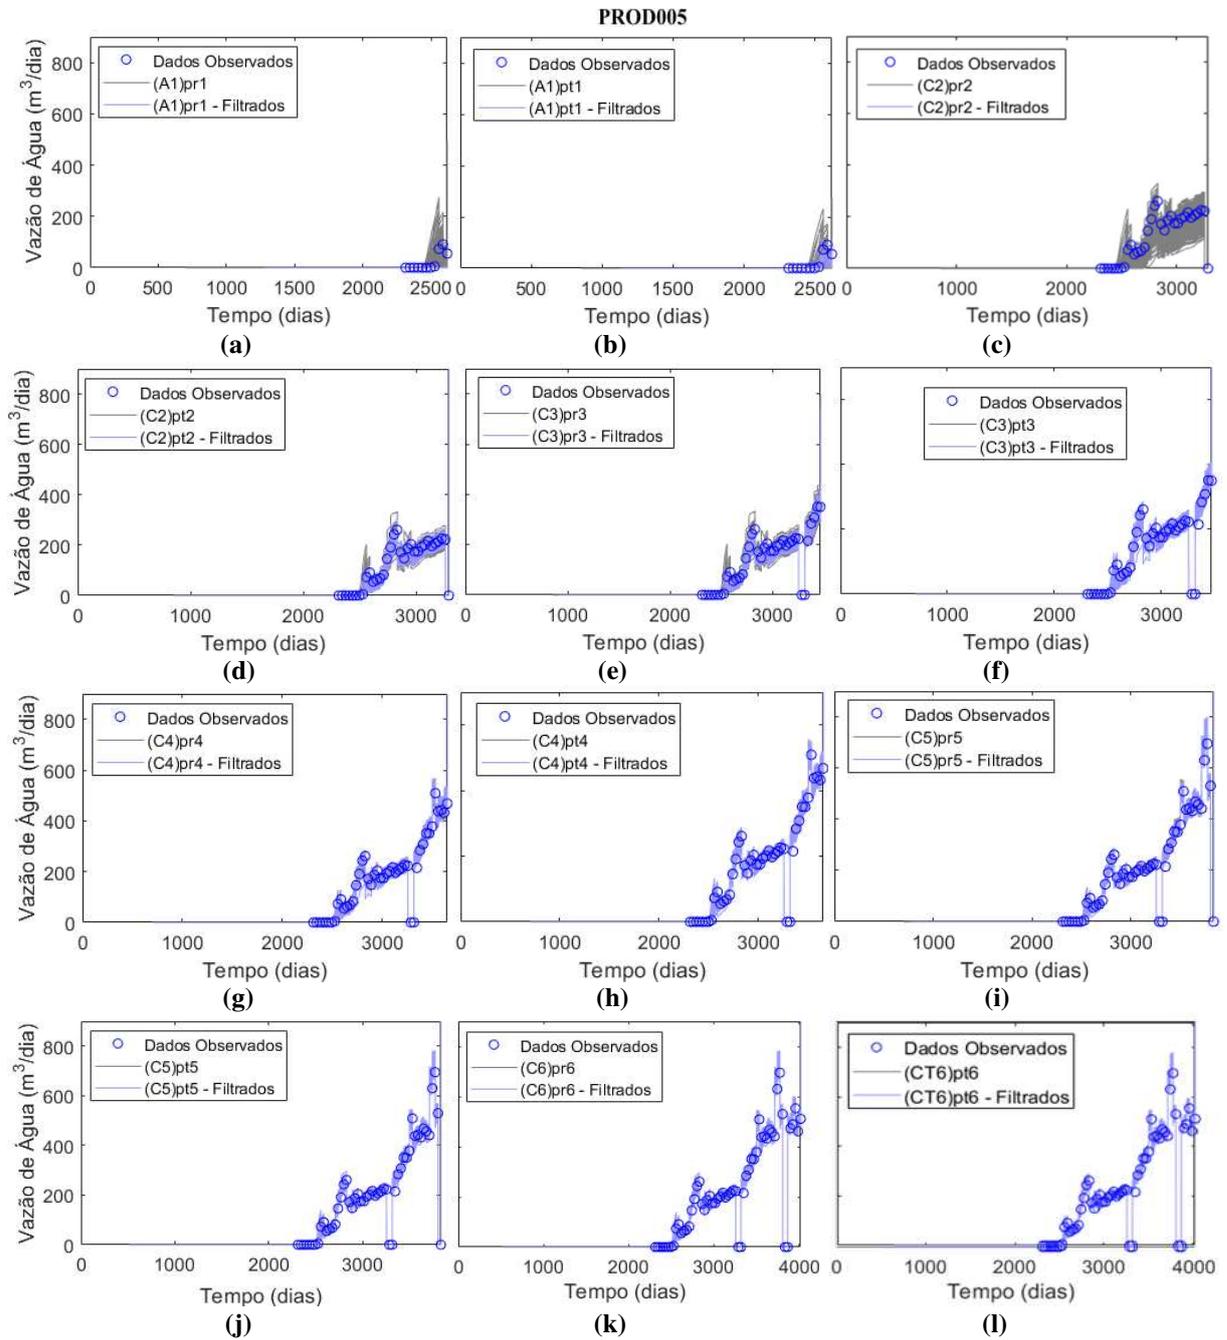


Figura 5.8: Curva de produção de água do poço produtor PROD005 (histórico) da abordagem B: (a) (A1)pr1; (b) (A1)pt1; (c) (C2)pr2; (d) (C2)pt2; (e) (C3)pr3; (f) (C3)pt3; (g) (C4)pr4; (h) (C4)pt4; (i) (C5)pr5; (j) (C5)pt5; (k) (C6)pr6 e (l) (C6)pt6.

5.2 Análise das incertezas

A Figura 5.9 mostra a evolução do desvio padrão normalizado das incertezas escalares da Abordagem A. Para cada atributo no eixo x, em cada ciclo, há uma variabilidade correspondente no eixo y. Tal como exposto na Equação (4.3), considera-se que no (A1)pr1 há 100% de variabilidade, no entanto, ao realizar o ajuste, esta variabilidade tende a ser reduzida.

Conforme mencionado na literatura, o ajuste de histórico com o ES-MDA sem o uso da técnica da localização normalmente tende a reduzir de forma excessiva a variabilidade dos atributos. Ao analisar a Figura 5.9, foi possível observar uma significativa redução da variabilidade para todos os atributos escalares em cada ciclo a posteriori em comparação com (A1)pr1. A única exceção foi o DWOC, que manteve em todos os ciclos uma variabilidade maior que 80%.

Essa significativa redução pode ser explicada pelo fato das incertezas escalares para o caso estudado (com exceção do DWOC, que é definido apenas no bloco leste) serem definidas com base em um único valor para todo o reservatório. Devido a este motivo, a técnica da localização não foi utilizada para atualizar estes atributos.

Além disso, observa-se que, após o (A1)pt1, a variabilidade se alterou muito pouco entre um ciclo e outro. Tomando como exemplo o k_{rwi} , no (A1)pr1 havia 100% de variabilidade e ao realizar o ajuste essa variabilidade foi reduzida, atingindo 17% no (A1)pt1. A partir do (A1)pt1, a variabilidade sofreu pequenas reduções até o (A3)pt3, com 8% de variabilidade. Nos próximos ciclos a variabilidade sofreu pequenos aumentos entre os ciclos até o (A6)pt6, com 15%.

Seguindo a mesma análise, a redução da variabilidade dos atributos escalares nas abordagens B (Figura 5.10) e C (Figura 5.11) foi mais significativa que na Abordagem A. Apesar da menor variabilidade no DWOC, o método preservou uma boa porcentagem da variabilidade. Pelo menos 50% de variabilidade foi preservada nos ciclos a posteriori.

Essa maior redução da variabilidade pode ser explicada pelo tipo de abordagem utilizada. No caso das abordagens B e C, a cada ciclo há um novo conjunto a priori, cuja variabilidade é menor que o ciclo anterior. Portanto, a cada ciclo, os sucessivos processos de redução de incertezas tendem a reduzir ainda mais a variabilidade dos atributos.

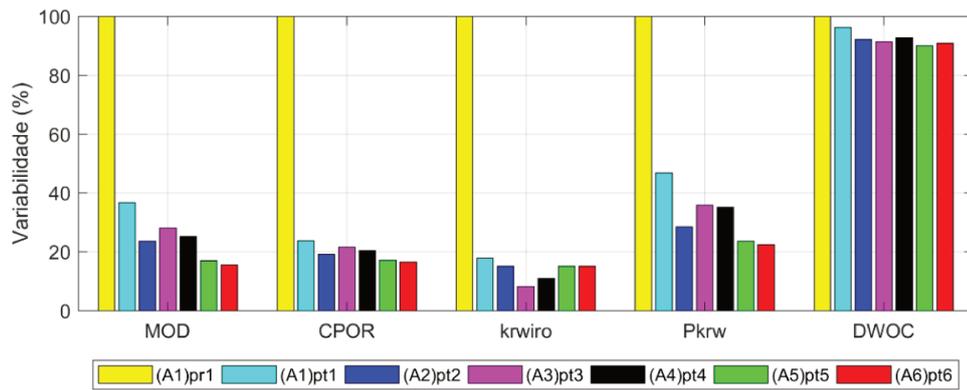


Figura 5.9: Desvio padrão normalizado dos atributos escalares da Abordagem A.

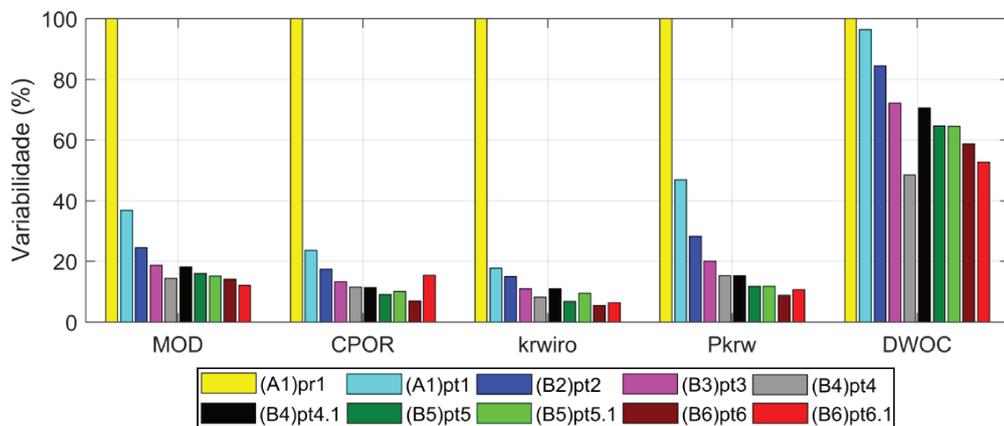


Figura 5.10: Desvio padrão normalizado dos atributos escalares da Abordagem B.

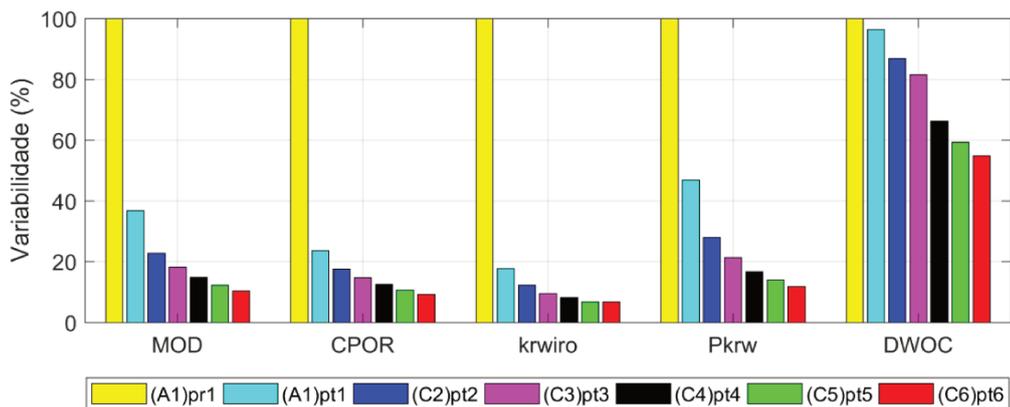


Figura 5.11: Desvio padrão normalizado dos atributos escalares da Abordagem C.

Vale a pena destacar que no (B4)pt4.1, (B5)pt5.1 e (B6)pt6.1 ocorreu uma reparametrização dos atributos MOD, DWOC e k_{rwiro} . Ao realizar o ajuste em determinado ciclo na Abordagem B, por exemplo, no Ciclo 4 observou-se um pico de probabilidade no último valor da pdf (Figura 5.12a). Isso significa que ao realizar a redução das incertezas, o método

encontrou valores fora dos limites estabelecidos, no entanto, realizou o truncamento para respeitá-los. Desta forma, ao observar este comportamento, foi necessário reparametrizar o limite máximo para gerar uma nova distribuição a priori. O ajuste foi realizado com base nesta nova distribuição e por este motivo não foi observado o pico de probabilidade (Figura 5.12b).

Com relação aos outros atributos citados o comportamento foi semelhante nos Ciclos 4, 5 e 6. Sendo que, para reparametrizar os atributos, um dos limites originais, mínimo e máximo, foi restabelecido para gerar uma nova distribuição a priori.

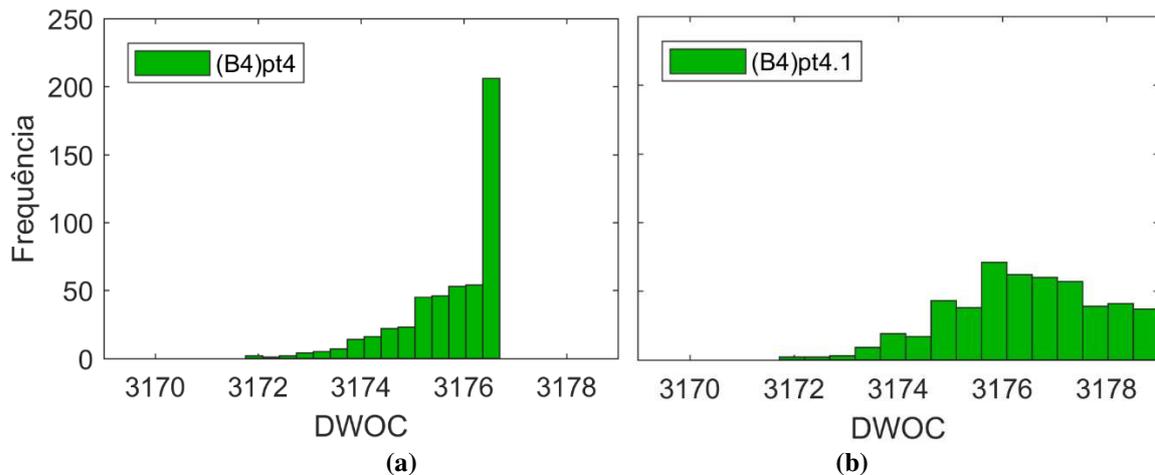


Figura 5.12: Exemplo do truncamento realizado pelo método no DWOC.

A Tabela 5.2 mostra a média para os atributos escalares das abordagens A, B e C no (A1)pr1 e nos ciclos a posteriori de cada abordagem. Para todos os atributos, à exceção do DWOC, os valores da média dos atributos variaram em cada ciclo das abordagens A, B e C. Este comportamento sugere que o método está convergindo para diferentes respostas entre um ciclo e outro. Como o DWOC é incerto apenas no bloco leste, somente os dados dos poços localizados neste bloco (PROD023A, PROD024A, PROD025A, INJ008 e INJ010) foram utilizados para sua atualização. Por este motivo, o método convergiu para valores próximos entre um ciclo e outro. Para os outros atributos, foram utilizados dados de todos os poços e isso dificultou a convergência para valores próximos.

Na Abordagem A, a evolução da média dos atributos não apresentou um padrão definido. Entre um ciclo e outro, a média reduziu ou aumentou para um mesmo atributo ao longo dos ciclos. Em outras palavras, a variação ocorreu sem convergir para uma determinada solução. Este comportamento pode ser explicado pelo fato da Abordagem A, em cada ciclo, utilizar sempre os mesmos atributos a priori no processo de aplicação do ES-MDA. Desta forma, o método acaba encontrando soluções diferentes entre um ciclo e outro. No entanto, encontrar

diferentes soluções não garante um bom ajuste. Visto que no (A3)pt3 e (A4)pt4 o método enfrentou dificuldade para ajustar a q_w , prejudicando a qualidade do ajuste do Total.

Tabela 5.2: Média das incertezas escalares das abordagens A, B e C.

Abordagem	Ciclo	MOD	CPOR ((kgf/cm ²) ⁻¹)	k_{rwiro}	P_{krw}	DWOC (m)
A	(A1)pr1	1.479	5.16E-05	0.33	2.352	3174
	(A1)pt1	1.548	6.33E-05	0.183	2.748	3173
	(A2)pt2	1.076	5.37E-05	0.214	2.317	3174
	(A3)pt3	1.963	5.23E-05	0.196	2.894	3173
	(A4)pt4	1.556	5.08E-05	0.199	2.692	3174
	(A5)pt5	1.141	5.76E-05	0.261	2.224	3175
	(A6)pt6	0.981	6.25E-05	0.313	2.375	3175
B	(A1)pr1	1.479	5.16E-05	0.33	2.352	3174
	(A1)pt1	1.548	6.33E-05	0.183	2.748	3173
	(B2)pt2	1.569	6.54E-05	0.196	2.743	3172
	(B3)pt3	1.403	6.65E-05	0.202	2.722	3173
	(B4)pt4.1	1.522	6.79E-05	0.214	2.728	3176
	(B5)pt5.1	1.427	6.95E-05	0.225	2.696	3176
	(B6)pt6.1	1.433	7.19E-05	0.224	2.659	3176
C	(A1)pr1	1.479	5.16E-05	0.33	2.352	3174
	(A1)pt1	1.548	6.33E-05	0.183	2.748	3173
	(C2)pt2	1.506	7.06E-05	0.197	2.582	3172
	(C3)pt3	1.49	7.30E-05	0.199	2.657	3172
	(C4)pt4	1.525	7.68E-05	0.205	2.759	3170
	(C5)pt5	1.525	7.96E-05	0.212	2.769	3170
	(C6)pt6	1.468	8.00E-05	0.217	2.768	3171

Comparando a evolução dos atributos que formam a permeabilidade relativa da água (k_{rwiro} e P_{krw}), nota-se que entre o (A2)pt2 e (A3)pt4, o método reduziu a média de k_{rwiro} e aumentou a média de P_{krw} . Em outras palavras, a k_{rw} foi reduzida. Entre o (A4)pt4 e (A6)pt6, o método aumentou k_{rwiro} e reduziu P_{krw} , aumentando assim a k_{rw} . Devido ao pico de produção de água nos (A3)pt3 e (A4)pt4, o método enfrentou dificuldades para ajustar a q_w . E somente no (A5)pt5, o método encontrou soluções que melhoram a qualidade do ajuste da q_w .

Para as abordagens B e C, conforme citado anteriormente, o método também encontrou diferentes soluções, no entanto, a variação entre um ciclo e outro foi menor em comparação com a Abordagem A. Por exemplo, entre o (B2)pt2 e o (B6)pt6.1, a média de k_{rwiro} aumentou e a do P_{krw} reduziu. O mesmo comportamento ocorreu entre o (C2)pt2 e o (C6)pt6. Em outras

palavras, o método tende a convergir para determinada solução, reduzindo a variabilidade dos atributos aos poucos.

Além disso, é possível observar que a Abordagem C apresenta uma maior liberdade em comparação com a Abordagem B. Pois, na primeira o limite de parametrização é o original, enquanto que na segunda, o limite muda a cada ciclo, restringindo ainda mais o limite de parametrização.

Por fim, as abordagens B e C, mesmo com uma menor variabilidade, apresentaram uma qualidade de ajuste muito superior em comparação com a Abordagem A. Dentre as variáveis de ajuste analisadas, destaca-se que o aumento na qualidade do ajuste da q_w , foi um dos fatores do aumento na qualidade do Total.

Para exemplificar a situação descrita anteriormente, a Figura 5.13, Figura 5.14 e Figura 5.15, mostram os histogramas da k_{rwi} , do P_{krw} e do DWOC das abordagens A, B e C.

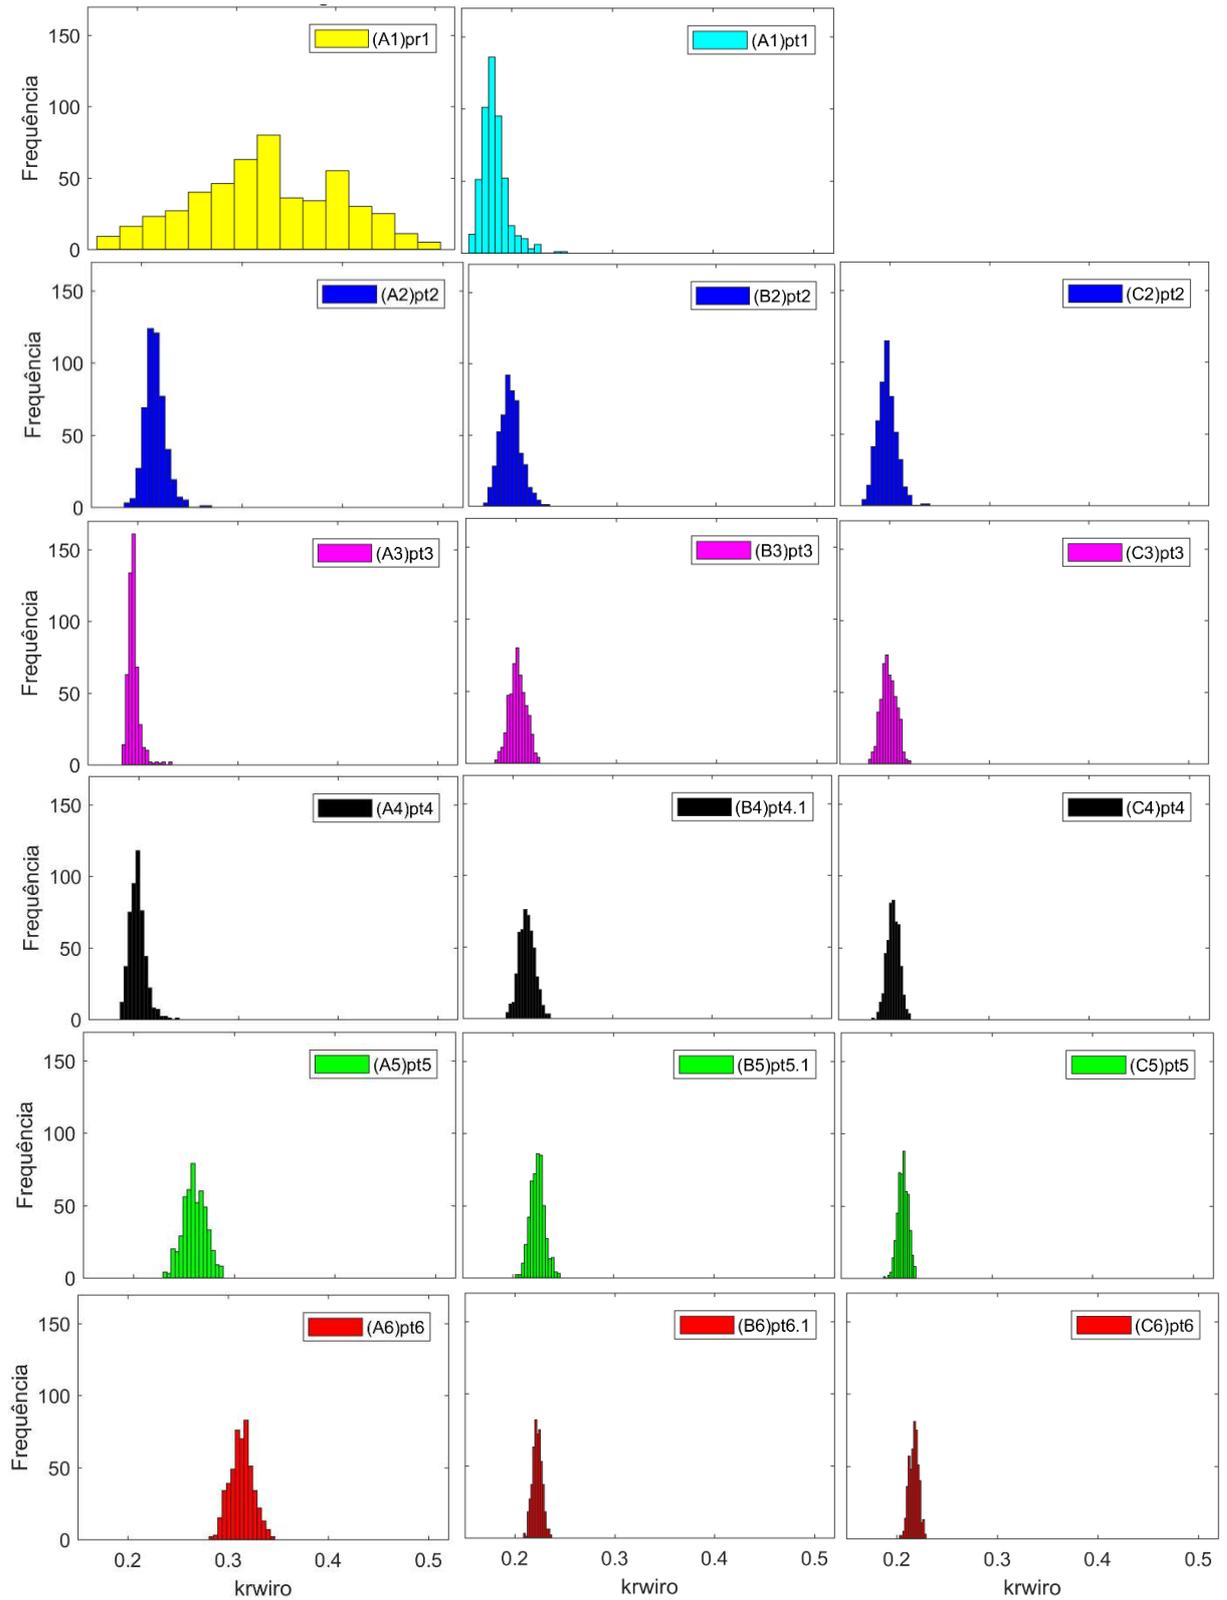


Figura 5.13: Histograma de k_{wiro} das abordagens A, B e C.

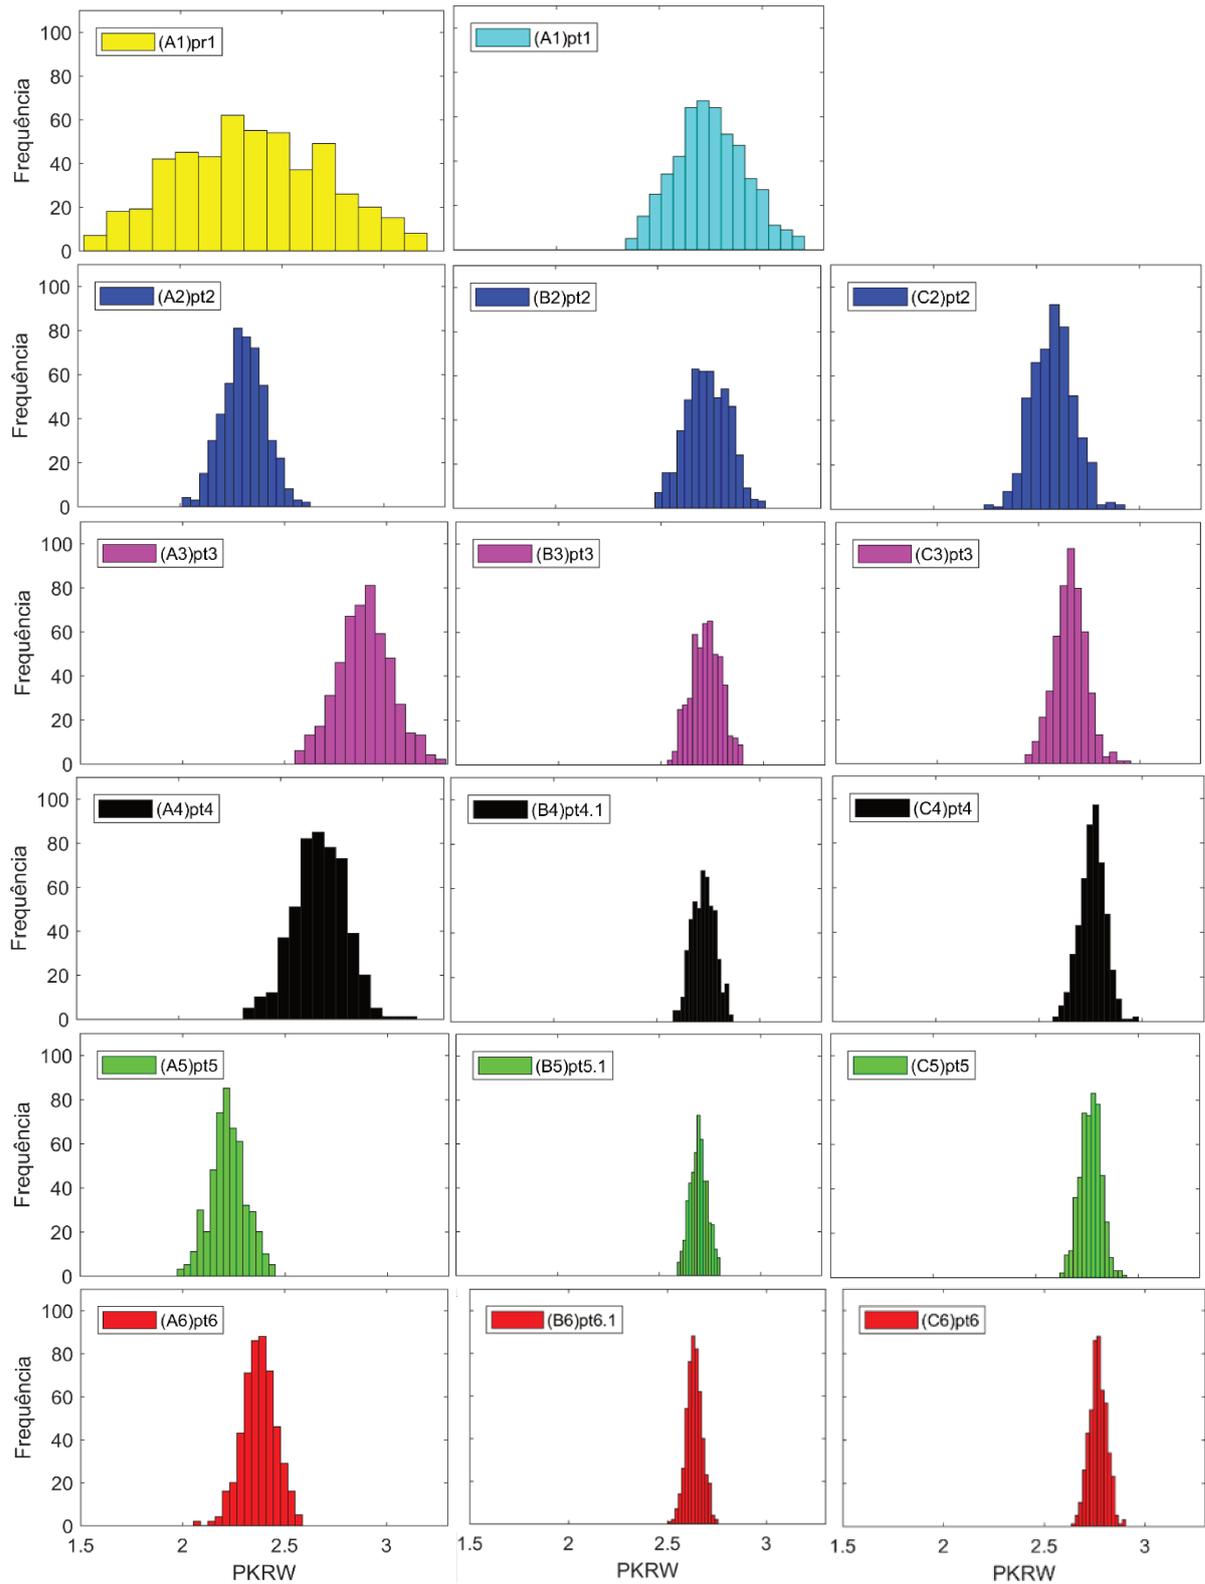


Figura 5.14: Histograma de P_{krw} das abordagens A, B e C.

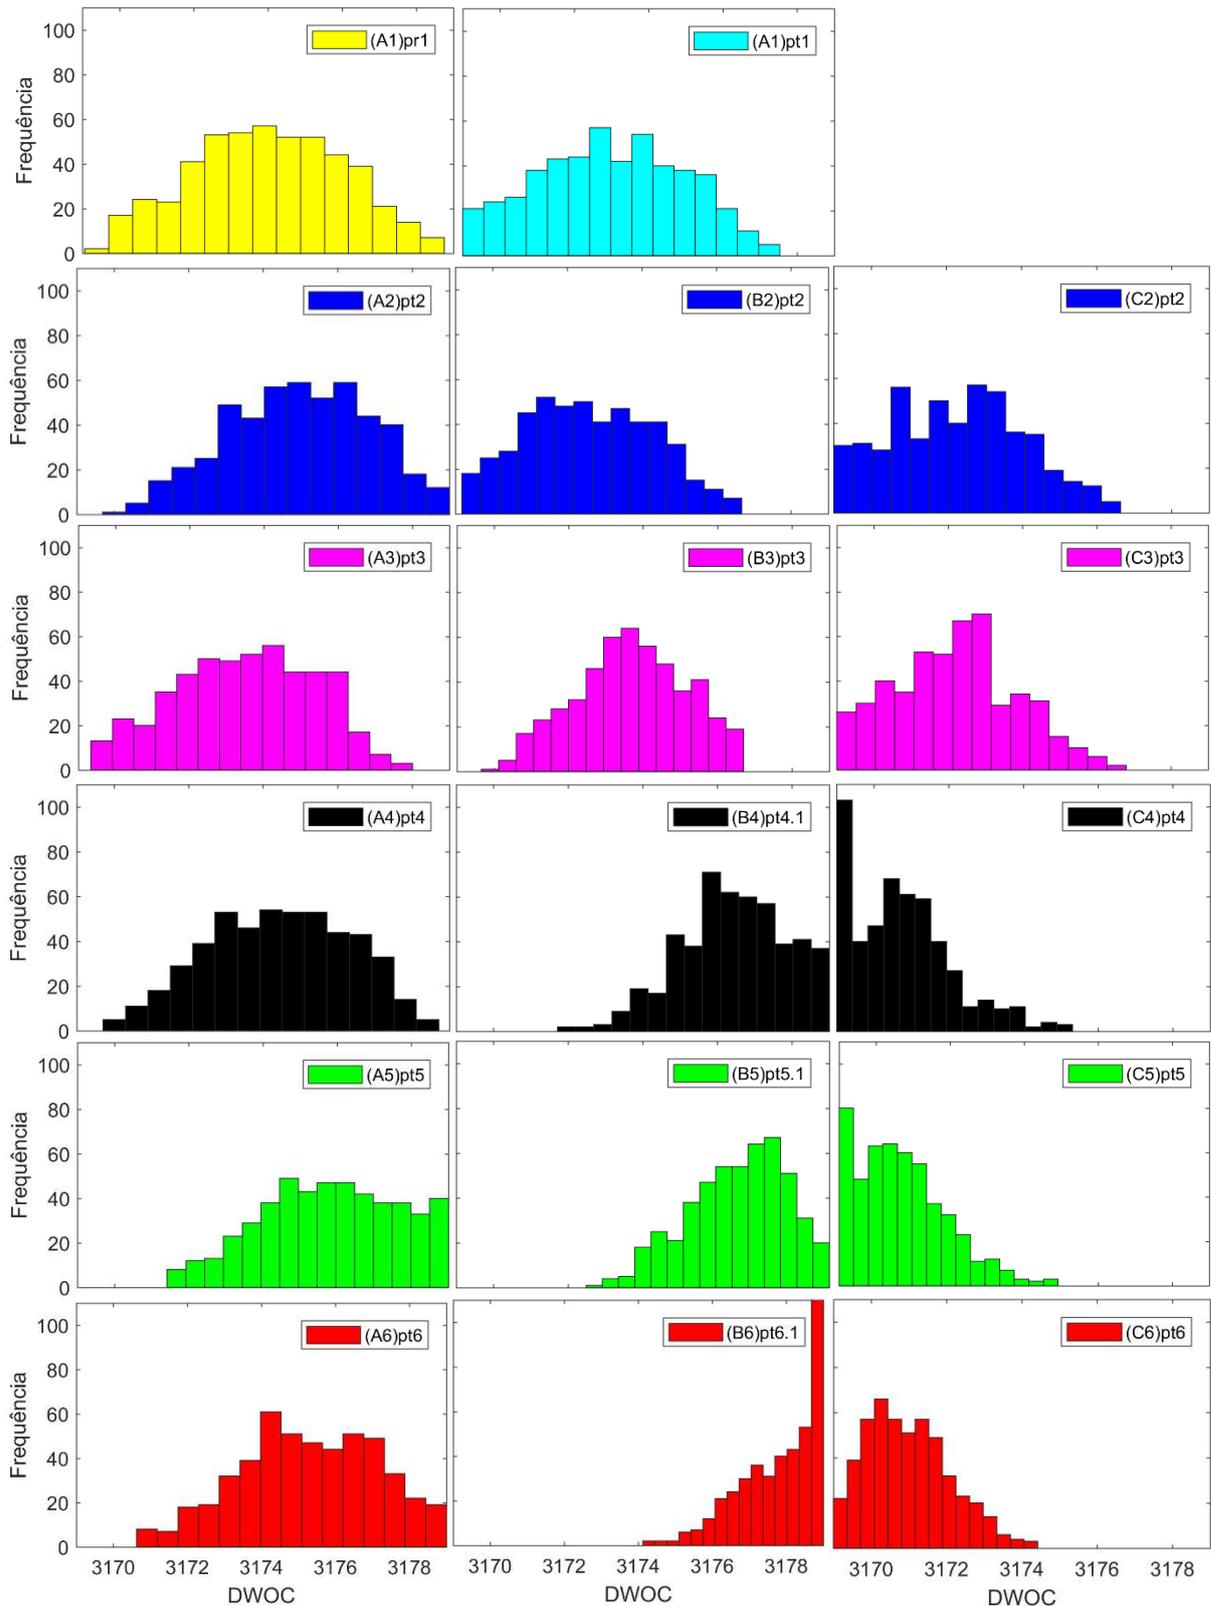


Figura 5.15: Histograma de DWOC das abordagens A, B e C.

Com relação aos atributos espaciais, devido ao uso da técnica da localização, havia uma grande dúvida sobre como o ES-MDA se comportaria em um processo de AHC. Esperava-se que o método, com uma menor quantidade de dados observados, reduzisse pouco a

variabilidade dos atributos. E com o aumento da quantidade de dados, a variabilidade fosse reduzida gradativamente.

A Figura 5.16 mostra o desvio padrão das 500 imagens do logaritmo natural de k_z ($\ln(k_z)$), para o (A1)pr1 e para os resultados a posteriori das abordagens A, B e C.

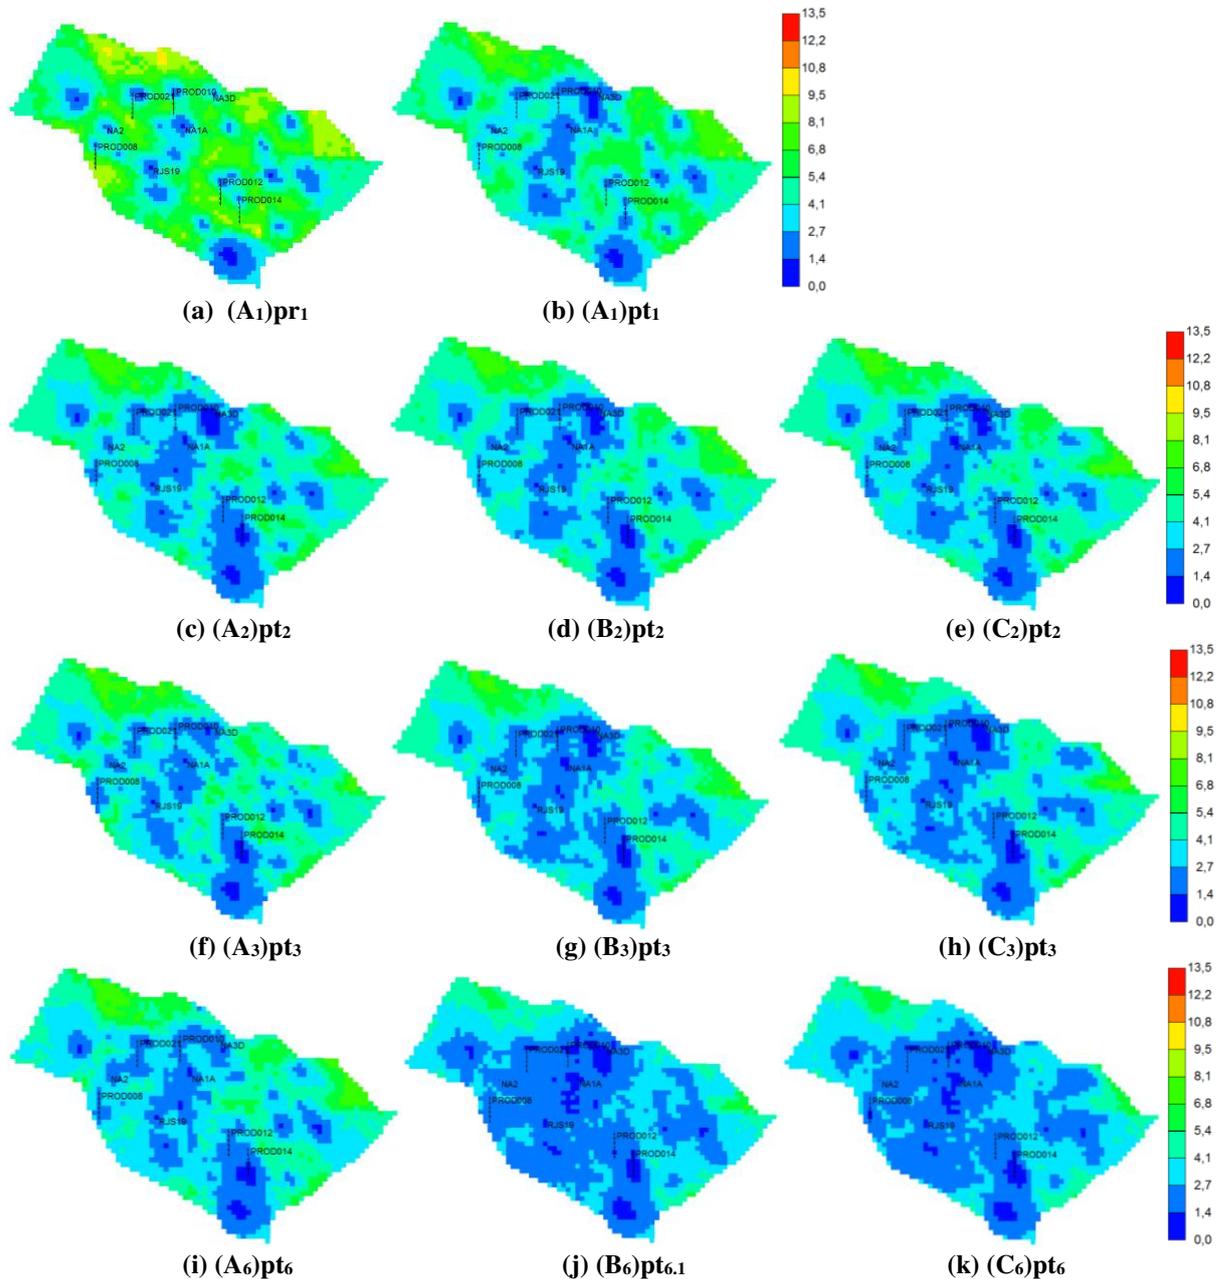


Figura 5.16: Desvio padrão da distribuição do $\ln(k_z)$ para alguns ciclos das abordagens A, B e C.

Ao comparar as três abordagens, constatou-se que o método reduziu pouco a variabilidade no (A1)pt1 em comparação com (A1)pr1. Entre o Ciclo 2 ((A2)pt2, (B2)pt2 e (C2)pt2) e o Ciclo 6 ((A6)pt6, (B6)pt6.1 e (C6)pt6) o método acabou reduzindo um pouco mais a variabilidade, embora a tenha preservado nas regiões distantes dos poços devido à técnica da localização.

Além disso, até o Ciclo 2, a variabilidade das três abordagens, (A2)pt2, (B2)pt2 e (C2)pt2, são semelhantes. No entanto, no (B3)pt3 e (C3)pt3, o método acabou reduzindo um pouco mais a variabilidade em comparação com (A3)pt3. O mesmo comportamento ocorreu até o Ciclo 6, pois, com a maior quantidade de dados observados o método tende a reduzir ainda mais a variabilidade. No (B6)pt6 e (C6)pt6, a variabilidade é bem menor em comparação com (A6)pt6, devido à utilização dos atributos a posteriori no processo de aplicação do ES-MDA.

Devido ao uso da localização, a correlação entre os atributos será maior nas regiões próxima aos poços e, por este motivo, a variabilidade será menor (região em azul). E nas regiões distantes, a correlação será menor e por isto a variabilidade tende a ser maior. De uma forma geral, para que os dados sejam assimilados é necessário reduzir a variabilidade dos atributos espaciais, como foi observado ao longo dos ciclos para todas as abordagens. Devido a este motivo, pode-se afirmar que o método reduziu a variabilidade de forma consistente e não excessiva ao longo dos ciclos. Para os outros atributos espaciais o comportamento foi semelhante.

Conforme citado anteriormente, a redução da variabilidade para todos os atributos ocorreu de forma consistente. Outra forma de evidenciar este resultado é pela comparação da média das imagens do $\ln(k_z)$ (Figura 5.17). Analisando os resultados, constatou-se uma certa semelhança do resultado a posteriori das abordagens A, B e C em comparação com o (A1)pr1. Além disso, no (A1)pt1 em comparação com (A1)pr1, o método aplicou poucas alterações, aumentando a permeabilidade somente nas regiões em volta dos poços sem perder a semelhança com as imagens a priori. Com uma maior quantidade de dados observados, o método aplicou maiores modificações, no entanto, sem perder parte da semelhança a priori, como pode ser observado a partir do Ciclo 2.

Por fim, nas abordagens B e C, o método aplicou maiores modificações em comparação com a Abordagem A, devido à utilização dos atributos a posteriori no processo de aplicação do ES-MDA. Apesar das modificações até o Ciclo 3 os mapas são semelhantes nas três abordagens. Adicionalmente, para todas as abordagens, observou-se que as regiões distantes (com menor correlação) não foram modificadas ou sofreram pequenas modificações. Por este motivo, todos os ciclos a posteriori se assemelham ao mapa de (A1)pr1.

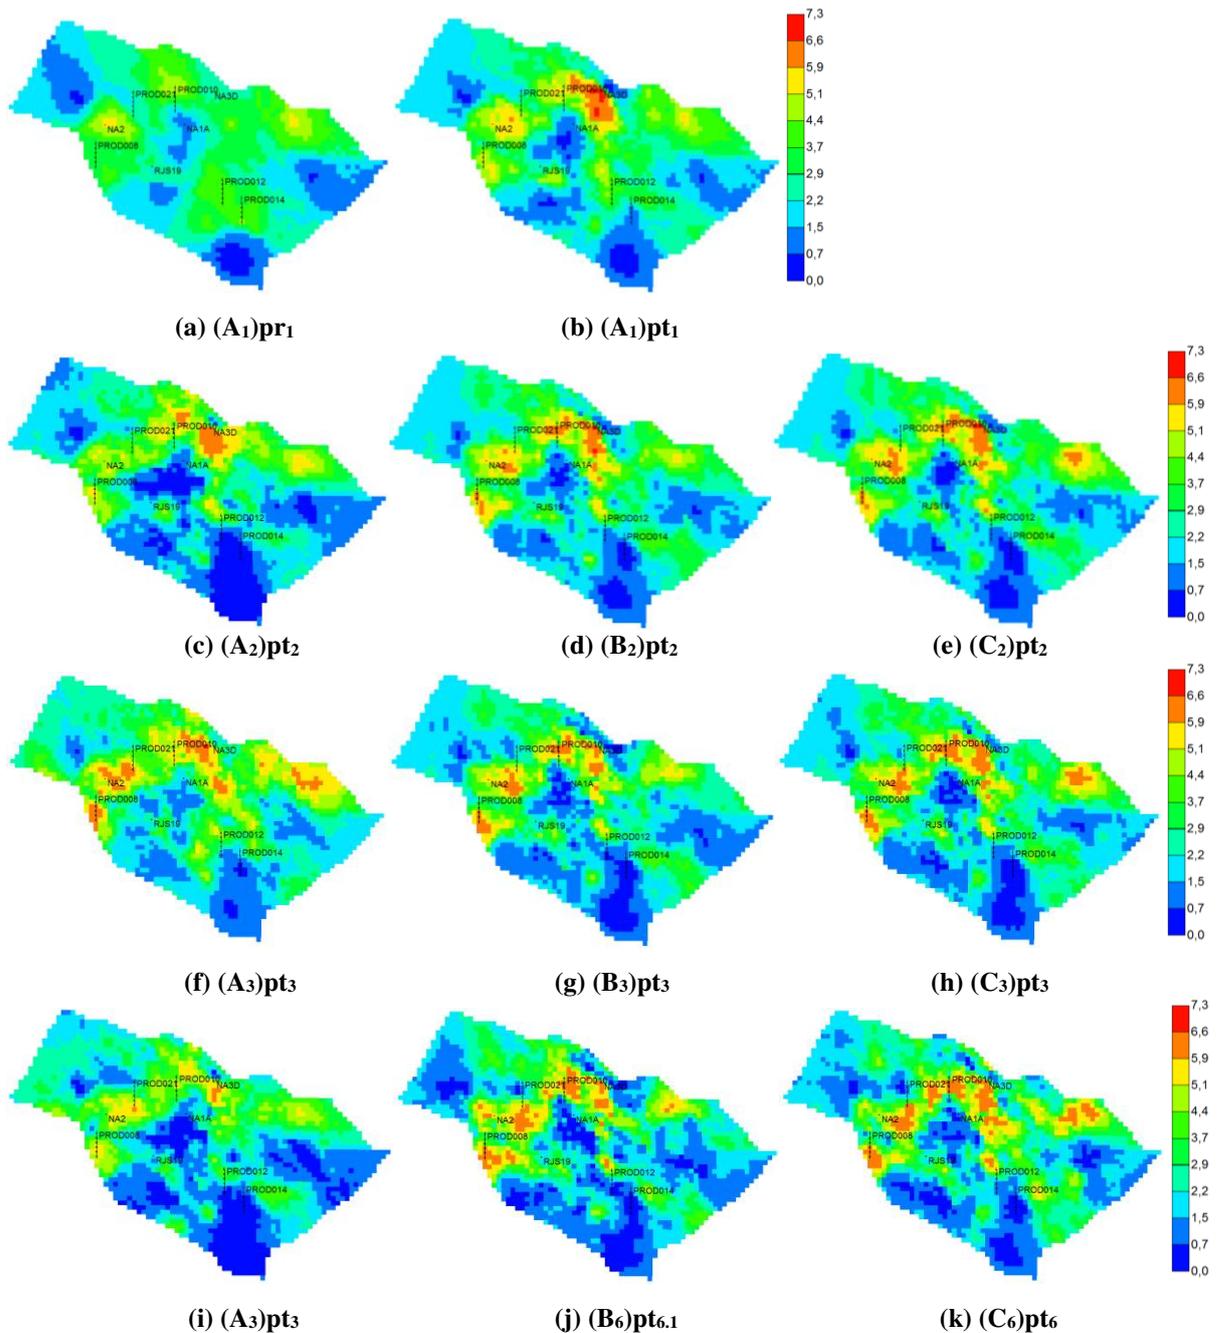


Figura 5.17: Média da distribuição do $\ln(kz)$.

5.3 Previsão da Produção

Para realizar a previsão da produção até 10957 dias, foi necessário selecionar os modelos filtrados levando em consideração uma restrição menos rigorosa da filtragem de modelos do Total. Essa restrição menos rigorosa é importante para evitar a redução excessiva da variabilidade na previsão. Desta forma, os modelos filtrados foram selecionados com base no $|AQNS|$ menor ou igual a 5.

A Tabela 5.3 mostra a filtragem de modelos para a etapa de previsão da produção, com base no $|AQNS|$ menor ou igual a 5. Da mesma forma que na análise do ajuste, é possível observar a limitação do ajuste quanto à q_w na Abordagem A e os melhores resultados nas abordagens B e C.

Tabela 5.3: Porcentagem dos modelos filtrados para a etapa de previsão da produção.

Modelos Filtrados (%)						
$ AQNS $	Ciclo	q_o	q_w	q_{wi}	BHP	Total
5	(A1)pr1	12.8	0	0	0.6	0
	(A1)pt1	100	52	63.4	79.8	26.4
	(A2)pt2	99.4	29.8	58.2	99.2	17
	(A3)pt3	74.6	10.4	93.2	100	9.6
	(A4)pt4	83.6	11.8	81	99.8	8.8
	(A5)pt5	98.6	43.6	91.2	100	39.8
	(A6)pt6	98.8	54.2	93	100	49.8
	(A1)pt1	100	52	63.4	79.8	26.4
	(B2)pt2	100	80.4	94.2	100	75.4
	(B3)pt3	100	96.6	99.6	100	96.2
	(B4)pt4.1	100	99.2	100	100	99.2
	(B5)pt5.1	100	99	100	100	99
	(B6)pt6.1	100	100	100	100	100
	(A1)pt1	100	52	63.4	79.8	26.4
	(C2)pt2	100	75.4	96.2	100	72
	(C3)pt3	100	96	99.8	100	95.8
	(C4)pt4	100	99.4	99.6	100	99
	(C5)pt5	100	98.4	100	100	98.4
	(C6)pt6	100	97.8	100	100	97.8

Primeiramente, foram traçadas as curvas de probabilidade acumulada de óleo (N_p) para todos os modelos de (A1)pr1 e dos ciclos a posteriori sem o filtro (Figura 5.18). As curvas de N_p do (A1)pr1 contemplaram a resposta do modelo referência (UNISIM-I-R), porém nenhum modelo passou pelo filtro.

Ao analisar o resultado a posteriori de N_p , notou-se uma redução da variabilidade dos modelos como consequência do processo de ajuste de histórico, conforme mostra a Figura 5.18a, Figura 5.18c, e Figura 5.18e. Na Abordagem A, somente no (A5)pt5 e (A6)pt6 a referência foi contemplada, superestimando a sua produção. Com relação à previsão dos modelos filtrados (Figura 5.18b), destaca-se que poucos modelos passaram pelo filtro no (A3)pt3 e (A4)pt4 como consequência da baixa qualidade do ajuste dos dados. E o (A5)pt5 e

(A6)pt6 continuaram contemplando a referência, embora a referência esteja bem na extremidade das curvas.

No entanto, nas abordagens B e C contemplou-se a referência a partir do (B2)pt2 e (C2)pt2, respectivamente (Figura 5.18c e Figura 5.18e). As curvas de probabilidade acumulada passaram a ser mais simétricas em relação à referência, se aproximando cada vez mais ao longo dos ciclos. Com relação à previsão dos modelos filtrados (Figura 5.18d e Figura 5.18f), verificou-se uma maior quantidade de modelos filtrados que continuaram a contemplar a referência a partir do (B2)pt2 e (C2)pt2, respectivamente. Essa maior quantidade de modelos filtrados está relacionada com a maior qualidade do ajuste dos dados nas abordagens B e C.

A Figura 5.19 mostra a previsão da produção de óleo acumulada do campo para os modelos filtrados do Ciclo 3 e 6 (a posteriori) das três abordagens (A, B e C). Na Figura 5.19a, observa-se que o (A3)pt3 não contemplou a referência durante todo o período de previsão. Adicionalmente, verifica-se que no início do tempo da previsão a resposta se encontra próxima da referência, mas, a resposta se distancia com o tempo.

No (B3)pt3 e o (C3)pt3, a referência passou a ser contemplada a partir da segunda metade do período de previsão, englobando mais adequadamente próximo do final devido ao aumento da variabilidade dos modelos (Figura 5.19c e Figura 5.19e). Com relação ao Ciclo 6 a posteriori ((A6)pt6, (B6)pt6.1 e (C6)pt6), os modelos contemplaram o referência durante todo o período de previsão. No entanto, a variabilidade dos modelos no (B6)pt6.1 e (C6)pt6 (Figura 5.19d e Figura 5.19f) foi um pouco menor em comparação (A6)pt6 (Figura 5.19b), devido à melhor qualidade do ajuste.

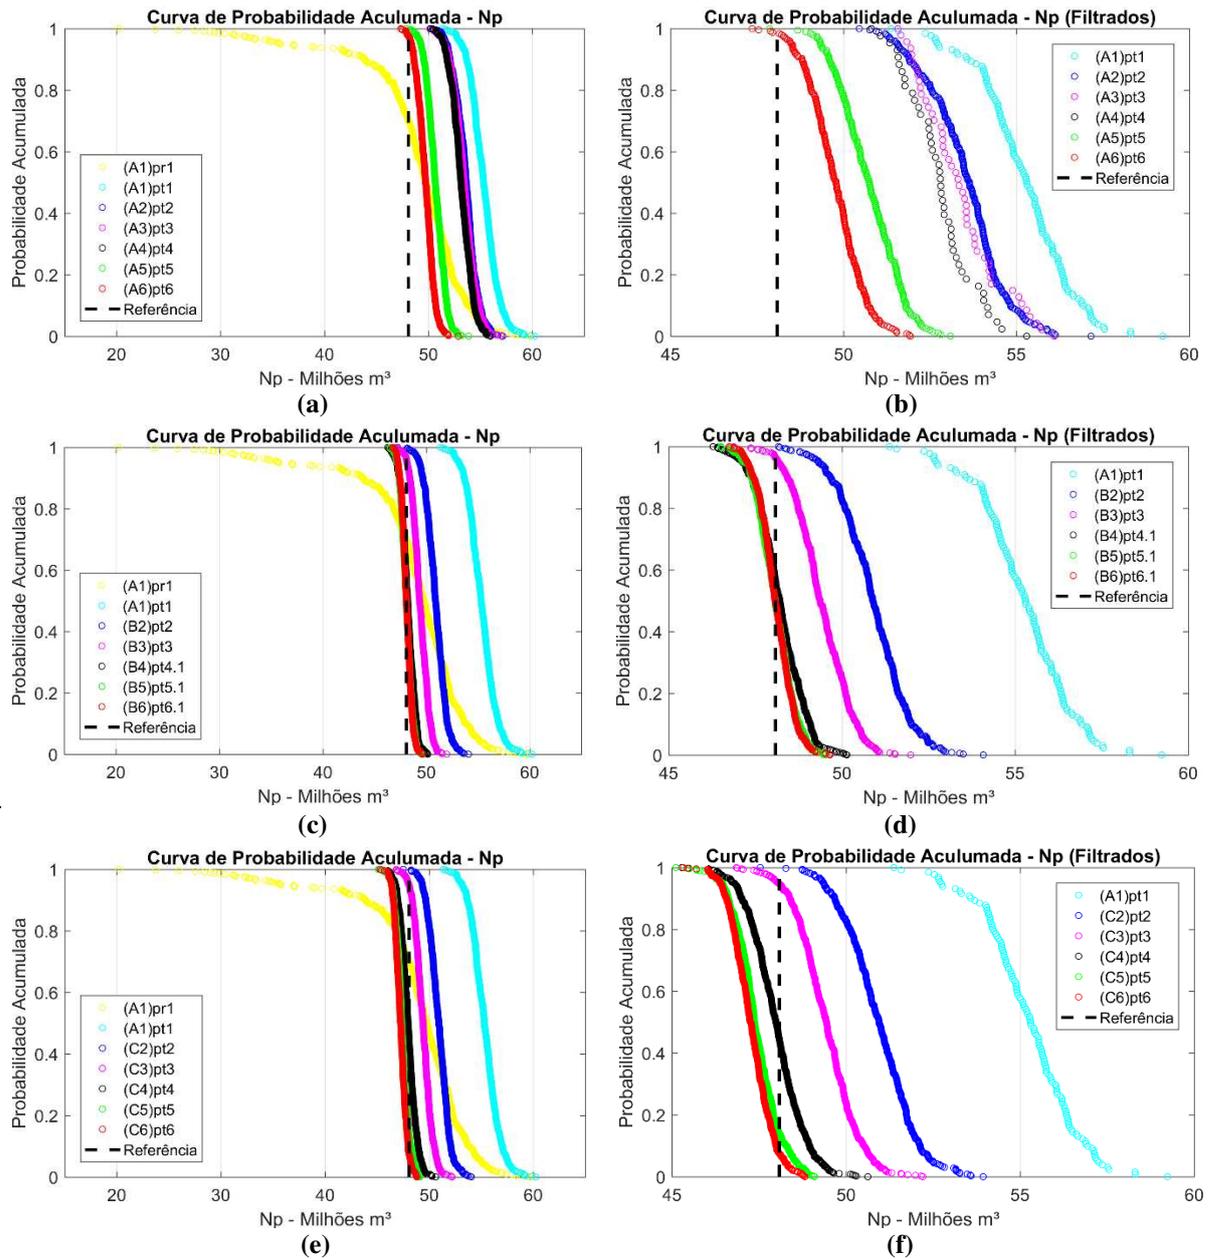


Figura 5.18: Curva de probabilidade acumulada para todos os modelos e modelos filtrados das abordagens A, B e C: (a) Abordagem A: N_p – sem filtro; (b) Abordagem A: N_p – com filtro; (c): Abordagem B: N_p – sem filtro; (d) Abordagem B: N_p – com filtro; (e) Abordagem C: N_p – sem filtro; e (f) Abordagem C: N_p – com filtro.

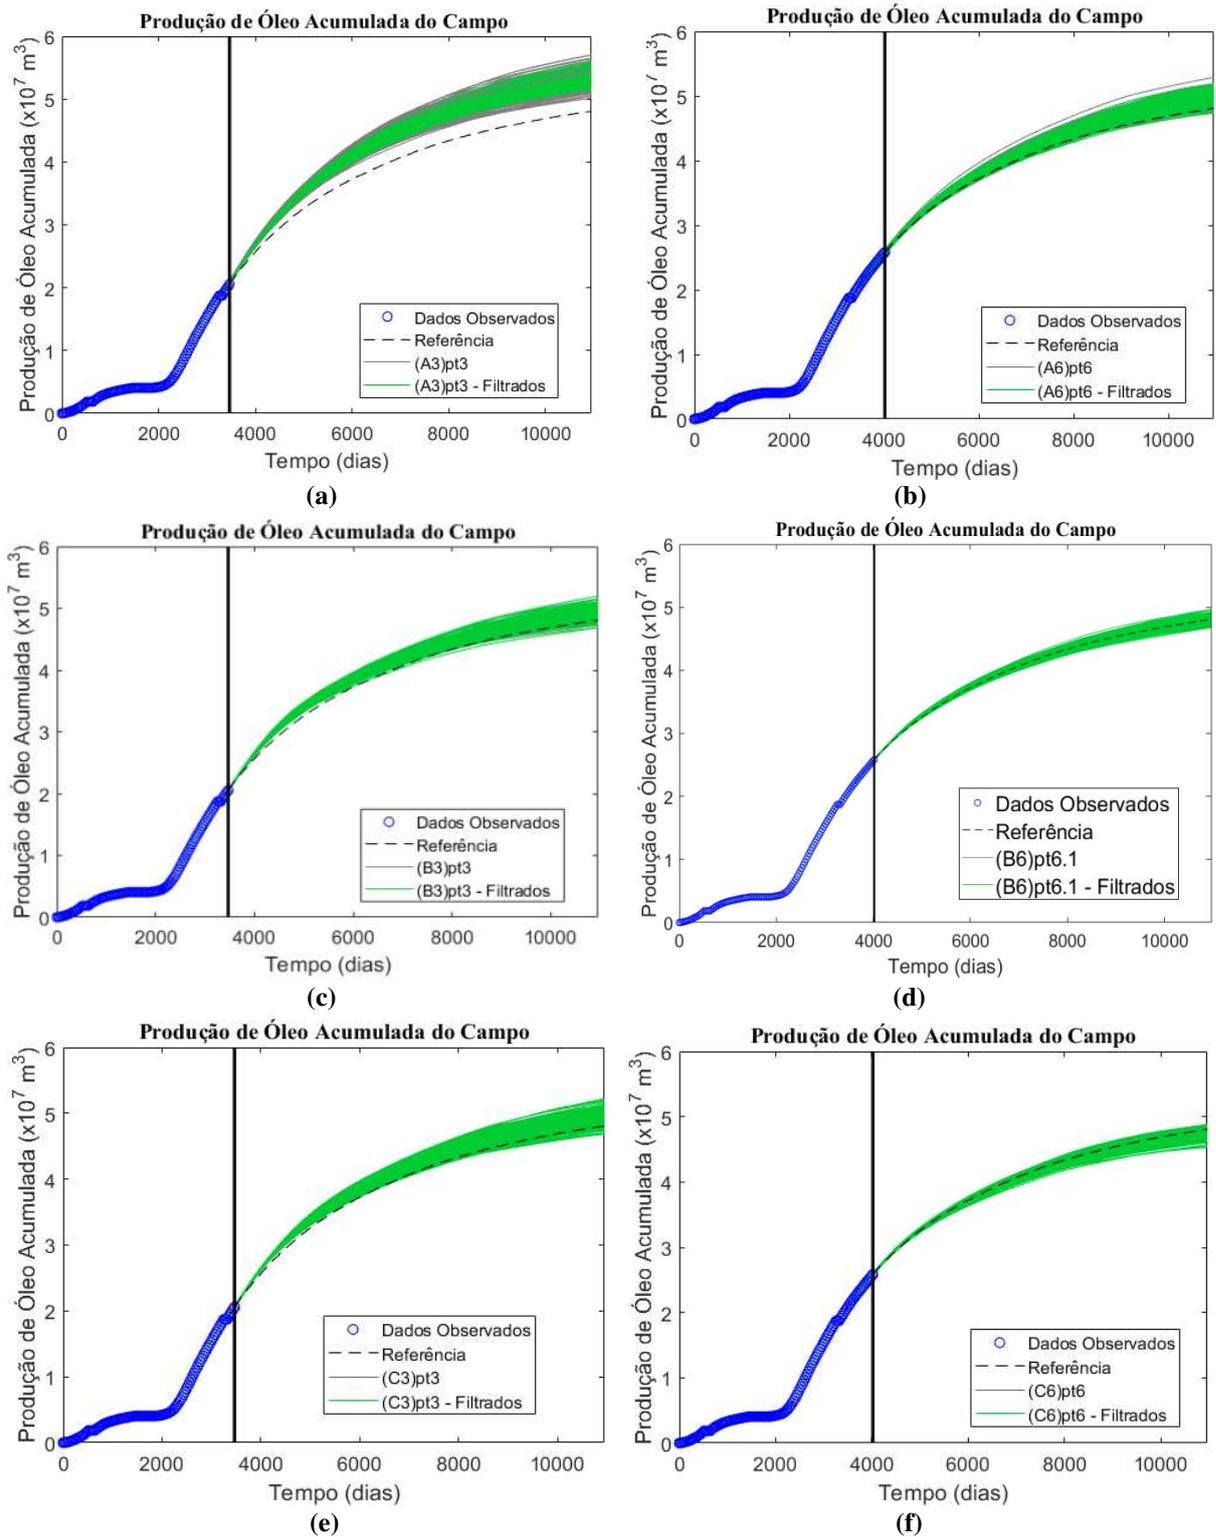


Figura 5.19: Previsão da produção: (a) N_p - (A3)pt3; (b) N_p - (A6)pt6; (c) N_p - (B3)pt3; (d) N_p - (B6)pt6.1; (e) N_p - (C3)pt3; (f) N_p - (C6)pt6.

Com relação ao W_p , também foram traçadas as curvas de probabilidade acumulada de água (W_p) para todos os modelos de (A1)pr1 e dos ciclos a posteriori sem o filtro (Figura 5.20).

As curvas de W_p do (A1)pr1 também contemplaram a resposta do modelo referência, porém nenhum modelo passou pelo filtro.

Ao analisar o resultado a posteriori, verificou-se que todos os ciclos a posteriori contemplaram a resposta do modelo de referência, sendo que as curvas são mais simétricas em relação à referência em todas as abordagens (Figura 5.20a, Figura 5.20c e Figura 5.20e). Na Abordagem A, a produção de água tende a ser subestimada nos ciclos iniciais. No entanto, nas abordagens B e C a produção de água é representada adequadamente em todos os ciclos. Ao analisar a previsão dos modelos filtrados para W_p , todos os ciclos continuaram a contemplar a resposta de referência nas três abordagens (Figura 5.20b, Figura 5.20d e Figura 5.20f).

A Figura 5.21 mostra a previsão da produção de água acumulada do campo para os modelos filtrados do Ciclo 3 e 6 (a posteriori) das três abordagens (A, B e C). Na Figura 5.21a, observou-se que o (A3)pt3 contemplou a referência somente no final do período da previsão, devido ao maior aumento da variabilidade dos modelos. No (B3)pt3 e (C3)pt3, a referência foi contemplada próxima ao final da previsão, no entanto, no início da previsão a resposta se encontra bem próxima da referência (Figura 5.21c e Figura 5.21e).

Com relação ao Ciclo 6 a posteriori ((A6)pt6, (B6)pt6.1 e (C6)pt6), os modelos contemplaram o referência durante todo o período de previsão. Sendo que, a variabilidade dos modelos no (B6)pt6.1 e (C6)pt6 (Figura 5.21d e Figura 5.21f) foi semelhante em comparação (A6)pt6 (Figura 5.21b).

Portanto, nas abordagens B e C, a qualidade do ajuste de histórico foi muito superior em comparação com a Abordagem A, principalmente para a q_w . Apesar da maior redução da variabilidade dos atributos, foi possível melhorar a qualidade do ajuste e da previsão da produção. Com relação à previsão, contemplou-se a referência a partir do Ciclo 2 nas abordagens B e C, enquanto que na Abordagem A, somente a partir do Ciclo 5.

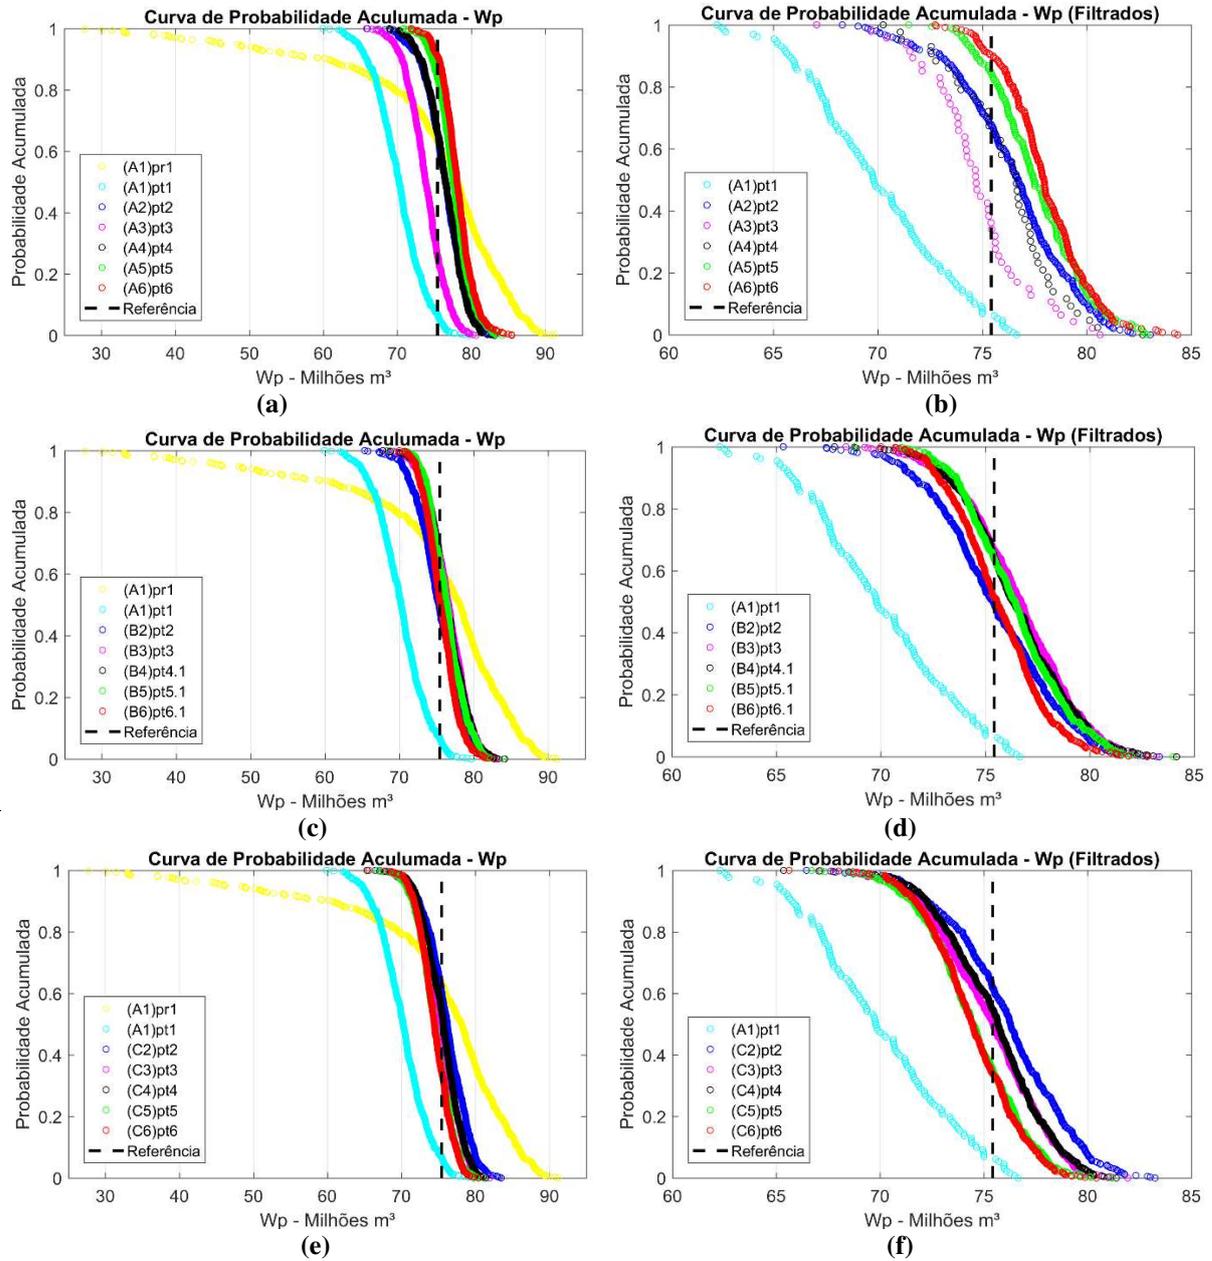


Figura 5.20: Curva de probabilidade acumulada para todos os modelos e modelos filtrados das abordagens A, B e C: (a) Abordagem A: W_p – sem filtro; (b) Abordagem A: W_p – com filtro; (c): Abordagem B: W_p – sem filtro; (d) Abordagem B: W_p – com filtro; (e) Abordagem C: W_p – sem filtro; e (f) Abordagem C: W_p – com filtro.

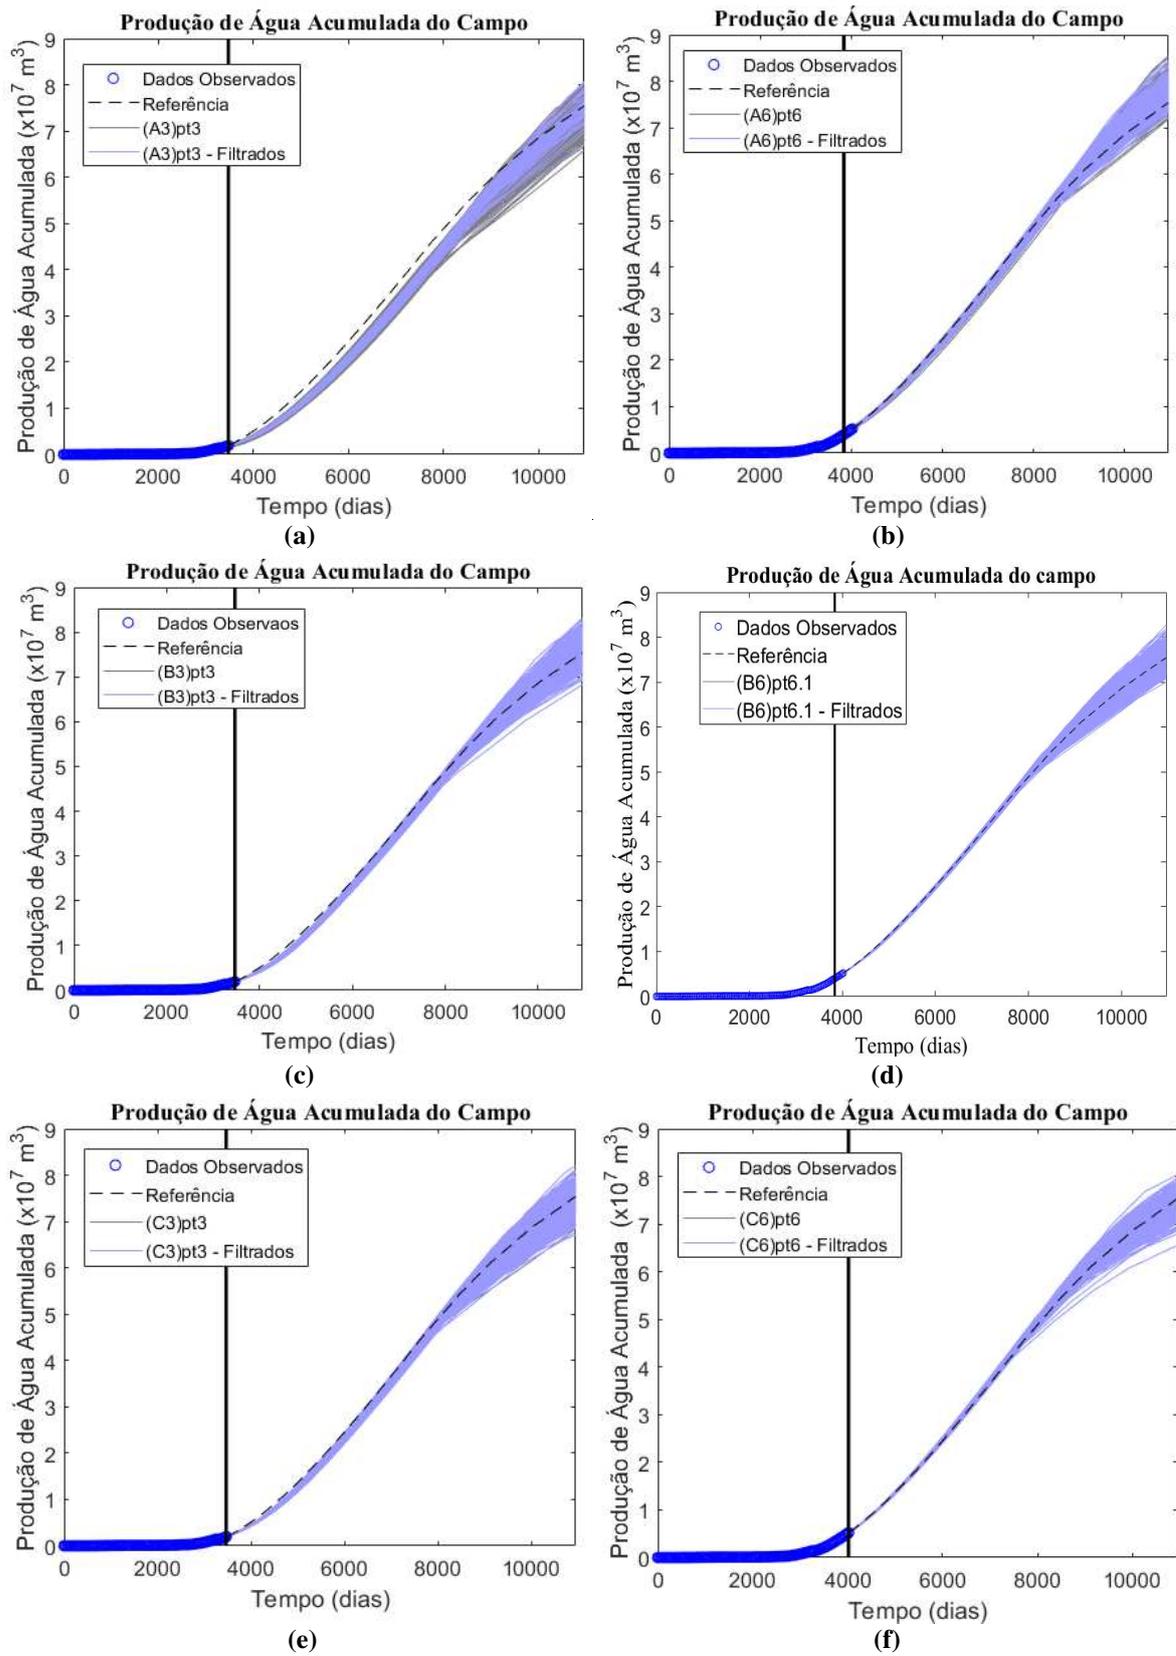


Figura 5.21: Previsão da produção: (a) W_p - (A3)pt3; (b) W_p - (A6)pt6; (c) W_p - (B3)pt3; (d) W_p - (B6)pt6.1; (e) W_p - (C3)pt3; (f) W_p - (C6)pt6.

6 CONCLUSÕES

Neste trabalho, foi proposta a aplicação de um método iterativo derivado do FK, o ES-MDA, em um processo de AHC sob diferentes abordagens para atualizar as incertezas dos atributos escalares e espaciais, visando analisar a influência de cada abordagem na qualidade do ajuste e da previsão da produção ao longo dos ciclos.

Após a aplicação do método ES-MDA, foi realizada uma análise da qualidade do ajuste utilizando uma FO multiobjetivo e também uma seleção dos modelos filtrados com base em um critério de aceitação previamente definido. Adicionalmente, foi realizada uma análise da variabilidade dos atributos de cada abordagem para verificar a ocorrência de redução excessiva das incertezas.

Com o objetivo de melhorar a qualidade do ajuste, três diferentes abordagens foram propostas. A primeira delas (Abordagem A), foi baseada nas incertezas a priori do Ciclo 1 (incertezas originais do modelo), a segunda (Abordagem B) e a terceira (Abordagem C), foram baseadas nas incertezas a posteriori (saída do ES-MDA) do ciclo anterior. No entanto, somente a segunda e a terceira foram promissoras quanto à qualidade do ajuste.

A aplicação de diferentes abordagens em um mesmo caso com características de um reservatório real e com resposta conhecida foi importante para comparar como os modelos ajustados se comportavam ao incluir novos dados observados. Essa comparação permitiu identificar possíveis discrepâncias entre o resultado simulado e a resposta real ao longo dos ciclos. Por ter sido utilizado um caso *benchmark*, foi possível observar se os modelos conseguiam manter o ajuste dos dados e também se contemplavam a referência (UNISIM-I-R) na previsão da produção.

As conclusões específicas são:

- A redução da variabilidade dos atributos espaciais foi mais significativa nas abordagens B e C em comparação com a Abordagem A. No entanto, ao final dos ciclos não se constatou a redução excessiva da variabilidade devido à técnica da localização.
- A redução da variabilidade dos atributos escalares ocorreu de forma excessiva nas três abordagens (A, B e C), devido ao fato de possuírem um único valor para todo o reservatório.
- Com o aumento da quantidade de dados observados a variabilidade dos atributos tende a reduzir, entretanto, reduzir as incertezas não garante um bom ajuste de histórico, visto que na Abordagem A, com o aumento da quantidade de dados ocorreu uma queda na

qualidade do ajuste no (A3)pt3 e (A4)pt4, principalmente devido à baixa qualidade do ajuste da q_w . Essa baixa qualidade de ajuste nestes ciclos resultou em divergência da resposta real na previsão até o Ciclo 4.

- O ajuste de histórico nas abordagens B e C apresentou melhores resultados em comparação com a Abordagem A. A incorporação de novos dados observados contribuiu diretamente para melhorar a qualidade do ajuste de histórico, melhorando ainda mais a qualidade do ajuste da q_w e melhorando a previsão da produção. Adicionalmente, foi possível observar que os modelos ajustados contemplaram a resposta do modelo de referência a partir do Ciclo 2 nas abordagens B e C, enquanto que na Abordagem A, a resposta do referência só foi contemplada a partir do Ciclo 5.
- Os modelos das abordagens B e C a partir do Ciclo 3 conseguiram manter o ajuste após a inclusão de dados observados. Pelo menos 30% dos modelos foram filtrados de acordo com a faixa de aceitação estabelecida e possivelmente não seria necessário realizar o ajuste de histórico, sendo uma economia no custo computacional.
- Por fim, a Abordagem C pode ser mais interessante em comparação com a Abordagem B para evitar a reparametrização dos atributos em caso de truncamento pelo método.

6.1 Recomendações para trabalhos futuros

Baseado no trabalho proposto, os seguintes estudos são sugeridos:

- Aplicação das incertezas espaciais a posteriori da saída do ES-MDA (ciclo anterior) e incertezas escalares a priori do Ciclo1.
- Estudar o impacto de diferentes números de ciclos e diferentes intervalos de tempo de histórico entre um ciclo e outro.
- Utilização de diferentes números de assimilações nos ciclos iniciais.
- Aplicação da metodologia em outros casos de estudo.

REFERÊNCIAS

AANONSEN, S. I.; NÆVDAL, G.; OLIVER, D. S.; REYNOLDS, A. C.; VALLÈS, B. The ensemble Kalman filter in reservoir engineering - a review. **SPE Journal**, v. 14, n. 3, p. 393-412, 2009.

ALMEIDA, F. L. R. **Metodologia de ajuste de histórico probabilístico e multiobjetivo integrando dados de produção e sísmica 4D**. Campinas, 2016. 156 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas - UNICAMP.

ALMEIDA, F. L. R.; FORMENTIN, H. N.; MASCHIO, C.; DAVOLIO, A.; SCHIOZER, D. J. Influence of additional objective functions on uncertainty reduction and history matching. **SPE Europec**, Copenhagen, Dinamarca, SPE 190804, 2018.

AVANSI, G. D. **Ajuste de histórico integrado à caracterização de reservatórios de petróleo e sísmica 4D**. 2014. 208 pp. Tese (Doutorado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

AVANSI, G.; SCHIOZER, D. UNISIM-I: Synthetic model for reservoir development and management applications. **International Journal of Modelling and Simulation for the Petroleum Industry**, v. 9, n. 1, p. 21-30. 2015.

BECERRA, G.G. **Mitigação de incertezas através da integração com ajuste de histórico de produção**. 2007. 230 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

BERTOLINI, A. C. **Probabilistic history matching methodology for real-time reservoir surveillance**. 2015. 104 pp. Tese (Doutorado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

BERTOLINI, A. C.; MASCHIO, C.; SCHIOZER, D. J. A methodology to evaluate and reduce reservoir uncertainties using multivariate distribution. **Journal of Petroleum Science and Engineering**, v. 128, p. 1-14, 2015.

CHEN, Y.; OLIVER, D. S.; ZHANG, D. Efficient ensemble-based closed-loop production optimization. **SPE Journal**, v. 14, n. 4, p. 634-645, 2009.

COMINELLI, A.; DOVERA, L.; VIMERCATI, S.; NÆVDAL, G. Benchmark study of ensemble Kalman filter methodology: history matching and uncertainty quantification for a

deep-water oil reservoir. **International Petroleum Technology Conference**. Doha, Catar, IPTC 13748, 2009.

COSTA, L. A.N. **Aplicação de redes neurais artificiais no processo de ajuste de histórico**. Campinas, 2012. 145 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas - UNICAMP.

EMERICK, A. A. Analysis of the performance of ensemble-based assimilation of production and seismic data. **Journal of Petroleum Science and Engineering**, v. 139, p. 210-239, 2016.

EMERICK, A. A.; REYNOLDS, A. C. Combining sensitivities and prior information for covariance localization in the ensemble Kalman filter for petroleum reservoir applications. **Computational Geoscience**, v.15, p. 251-269. 2011.

EMERICK, A. A.; REYNOLDS, A. C. Ensemble smoother with multiple data assimilation. **Computers & Geoscience**, v. 55, p. 3-15, 2013.

EMERICK, A. A.; REYNOLDS, A. C., History matching time-lapse seismic data using the ensemble Kalman filter with multiple data assimilations. **Computational Geosciences**, v. 16, n. 3, p. 639-659, 2012.

EVENSEN, G. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. **Journal of Geophysical Research**, v. 99, n.5, p. 10143-10162, 1994.

EVENSEN, G. The ensemble Kalman filter for combined state and parameter estimation. **IEEE Control Systems**, v. 29, n. 3, p. 83 - 104, 2009.

GASPAR, A. T.; AVANSI, G. D.; MASCHIO, C.; SANTOS, A. A.; SCHIOZER, D. J. UNISIM-I-M: Benchmark case proposal for oil reservoir management decision-making. **SPE Trinidad and Tobago Section Energy Resources Conference**. Porto de Espanha, Trindade e Tobago, SPE 180848, 2016.

GASPARI, G.; COHN, S. Construction of correlation functions in two and three dimensions. **Quarterly Journal of the Royal Meteorological Society**, v. 125, n. 554, p. 723- 757, 1999.

GIRELI, G. A. S. **Método de otimização híbrido aplicado ao processo de ajuste de histórico assistido**. 2016. 131 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

GU, Y.; OLIVER, D. S. The ensemble Kalman filter for continuous updating of reservoir simulation models. **Journal of Energy Resources Technology**, v. 128, n. 1 p. 79-87, 2006.

JANSEN, J. D.; BROUWER, D. R.; NAEVDAL, G.; VAN KRUIJSDIJK, J. W. Closed-loop reservoir management. **First Break**, v. 23, p. 43–48. 2005.

MASCHIO, C.; DE CARVALHO, C. P. V.; SCHIOZER, D. J. A new methodology to reduce uncertainties in reservoir simulation models using observed data and sampling techniques. **Journal of Petroleum Science and Engineering**, v. 72, n. 1-2, p. 110–119, 2010.

MASCHIO, C.; SCHIOZER, D. J. Bayesian history matching using artificial neural network and Markov Chain Monte Carlo. **Journal of Petroleum Science and Engineering**, v. 123, p.62-71, 2014.

MASCHIO, C.; SCHIOZER, D. J. Probabilistic history matching using discrete Latin Hypercube sampling and nonparametric density estimation. **Journal of Petroleum Science and Engineering**, v. 147, p.98-115, 2016

MOROSOV, A. L. **Evolução do risco durante o desenvolvimento de campos de petróleo**. 2016. 135 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

MOURA FILHO, M. A. B. **Integração de análise de incertezas e ajuste de histórico de produção**. 2006. 131 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

OBERWINKLER, C. P.; STUNDNER, M. From real time data to production optimization. **Proceedings of SPE Asia Pacific Conference on Integrated Modelling for Asset Management**, Kuala Lumpur, Malásia, SPE-87008-MS, 2004.

OLIVER, D. S.; CHEN, Y. Recent progress on reservoir history matching: a review. **Computational Geosciences**, v. 15, p. 185-221, 2011.

SCHIOZER, D. J.; SANTOS, A. A. S.; DRUMMOND, P. S. Integrated model based decision analysis in twelve steps applied to petroleum fields development and management. **SPE Europec**. Madri, Espanha, SPE 174370, 2015.

SILVA, F. B. M. **Desenvolvimento de indicadores para sistematização do ajuste de histórico de produção probabilístico**. 2016b. 127 pp. Dissertação (Mestrado) – Faculdade de

Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

SILVA, L. S. **Integração de análise de incertezas e ajuste de histórico: Aplicação em um caso complexo.** 2011. 142 pp. Dissertação (Mestrado) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

SILVA, V. L. S. **Ajuste de histórico e otimização da produção de petróleo sob incertezas - aplicação do gerenciamento de reservatórios em malha fechada.** 2016a. 106 pp. Dissertação (Mestrado) - Programa de Engenharia Civil, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

SKJERVHEIM, J. -A.; EVENSEN, G.; HOVE, J.; VABØ, J. G. An ensemble smoother for assisted history matching. **Proceedings of the SPE Reservoir Simulation Symposium.** The Woodlands, EUA, SPE 141929, 2011.

SOARES, R. V. **Influência da técnica da localização do ganho de Kalman no ajuste de histórico de produção.** 2017. 120 pp. Dissertação (Mestrado) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, Campinas.

SOARES, R. V.; MASCHIO, C.; SCHIOZER, D. J. Applying a localization technique to Kalman gain and assessing the influence on the variability of models in history matching. **Journal of Petroleum Science and Engineering**, v. 169, p. 110–125, 2018.

VAN LEEUWEN, P. J.; EVENSEN, G. Data assimilation and inverse methods in terms of a probabilistic formulation. **Monthly Weather Review**, v. 124 p. 2898-2913, 1996.

WANG, C.; LI, G.; REYNOLDS, A. C. Production optimization in closed-loop reservoir management. **SPE Journal**, v. 14, n. 03, p. 506-523, 2009.

WEN, X-H., CHEN, W. H. Real-time reservoir model updating using ensemble Kalman filter. **SPE Reservoir Simulation Symposium.** The Woodlands, EUA, SPE 92991, 2005.

APÊNDICE A – GRÁFICOS DE FILTRAGEM DE MODELOS

A seguir são apresentados gráficos da filtragem de modelos (a priori e a posteriori) para q_0 , BHP dos produtores, q_{wi} e BHP dos poços injetores das três abordagens (A, B e C) com base no $|AQNS|$.

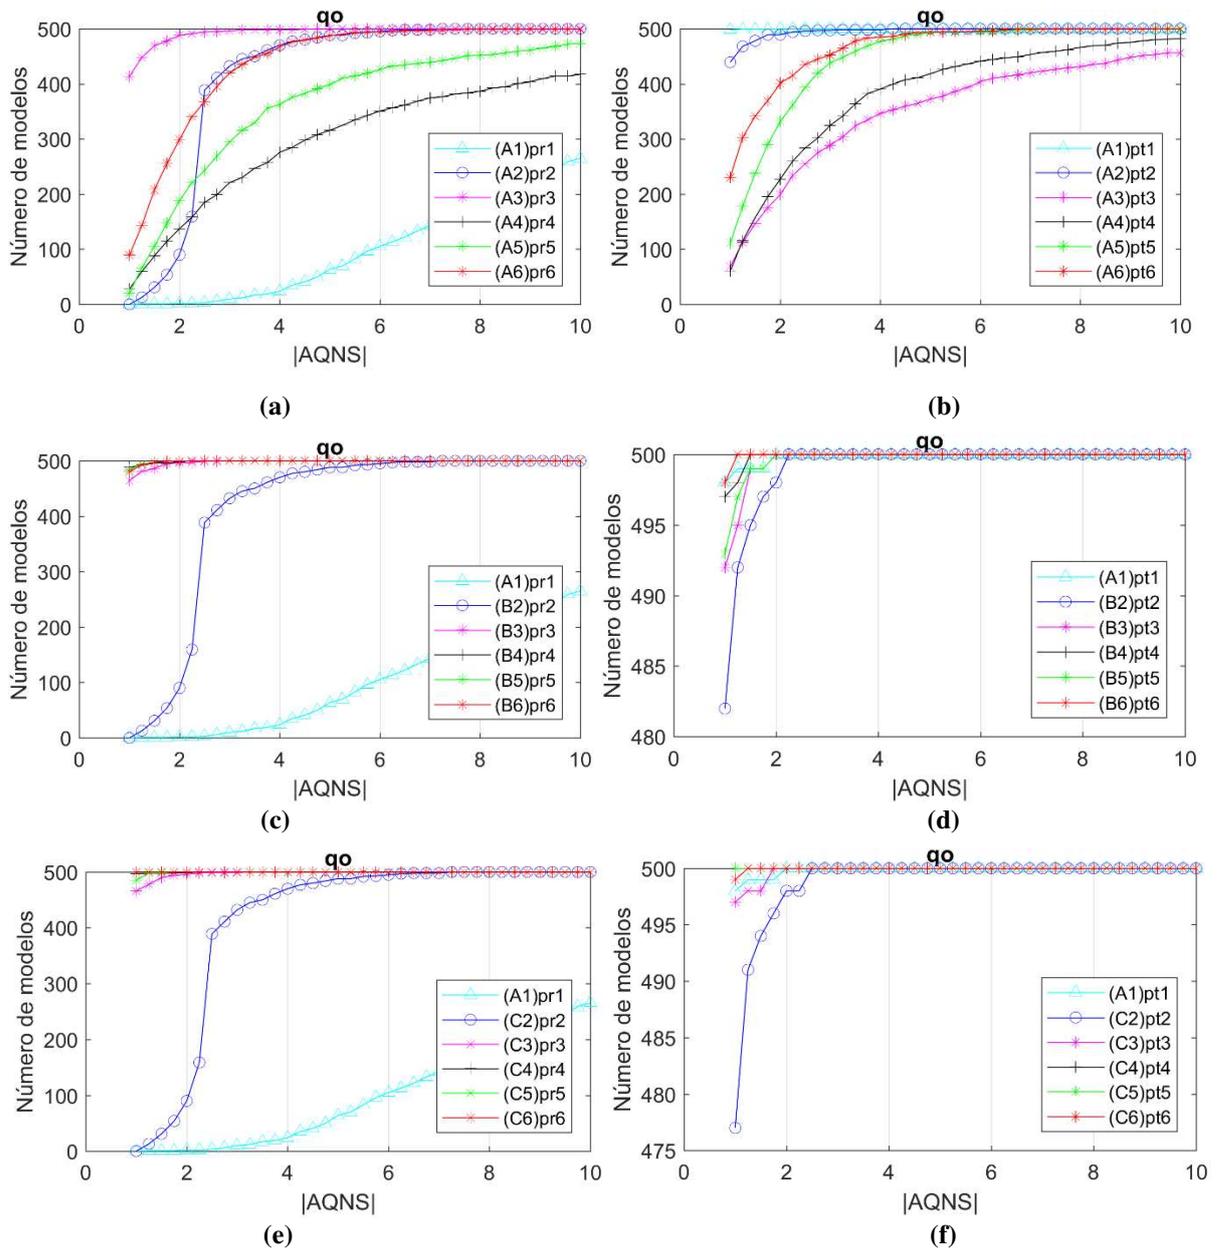


Figura A. 1: Filtragem de modelos para a q_0 das abordagens A, B e C com base no $|AQNS|$: (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.

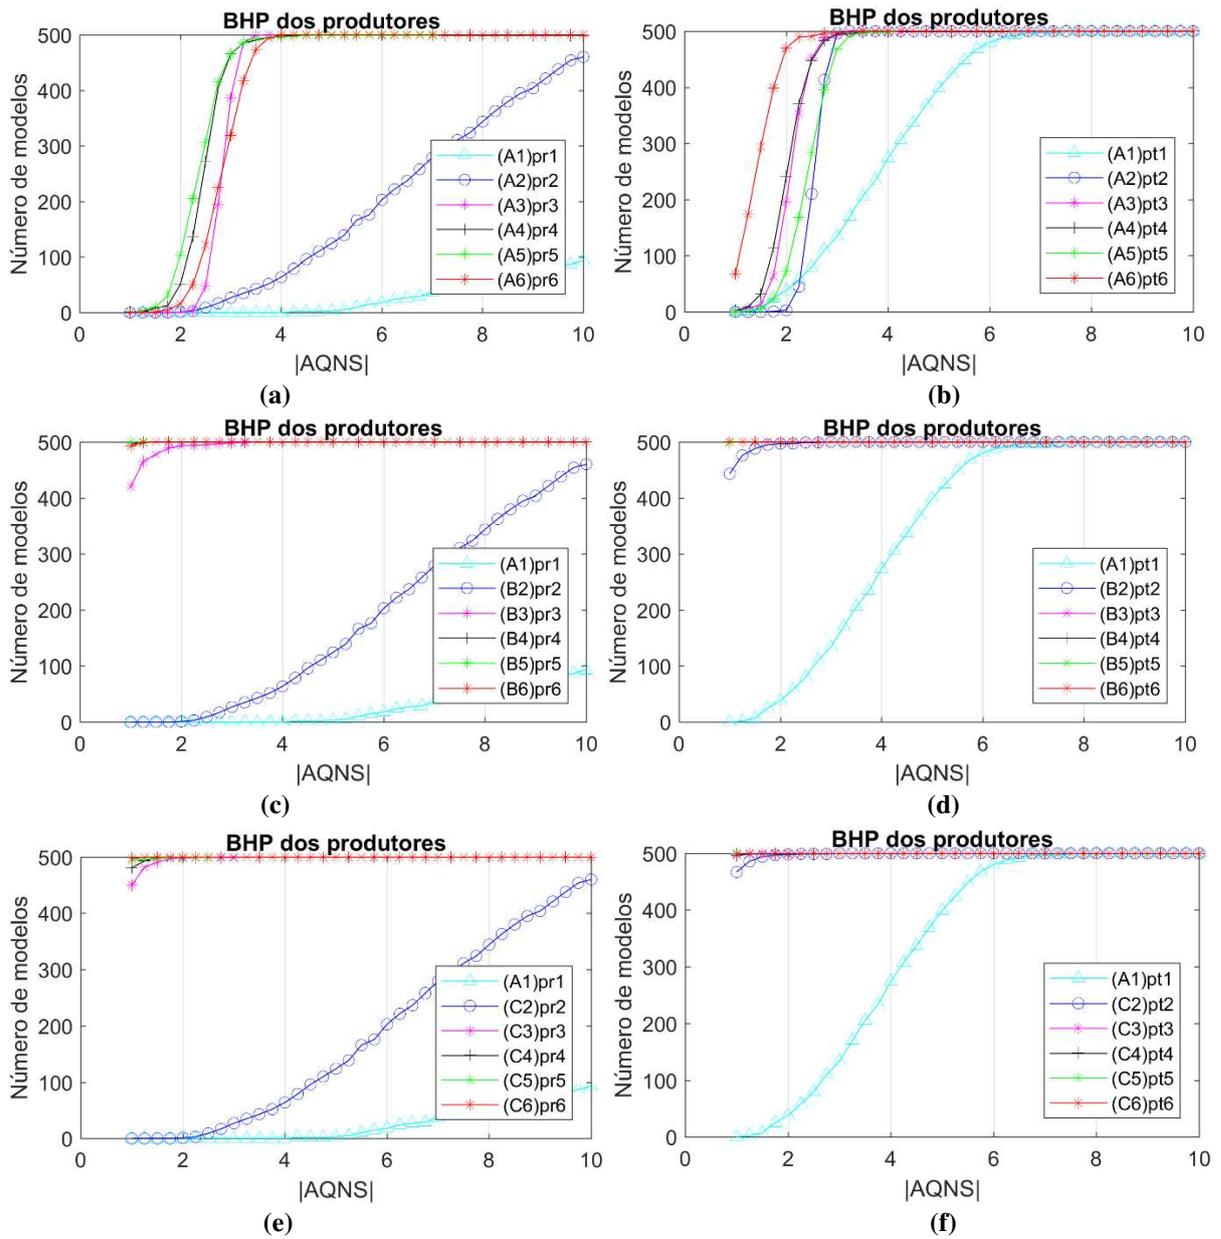


Figura A. 2: Filtragem de modelos para o BHP dos produtores das abordagens A, B e C com base no $|AQNS|$: (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.

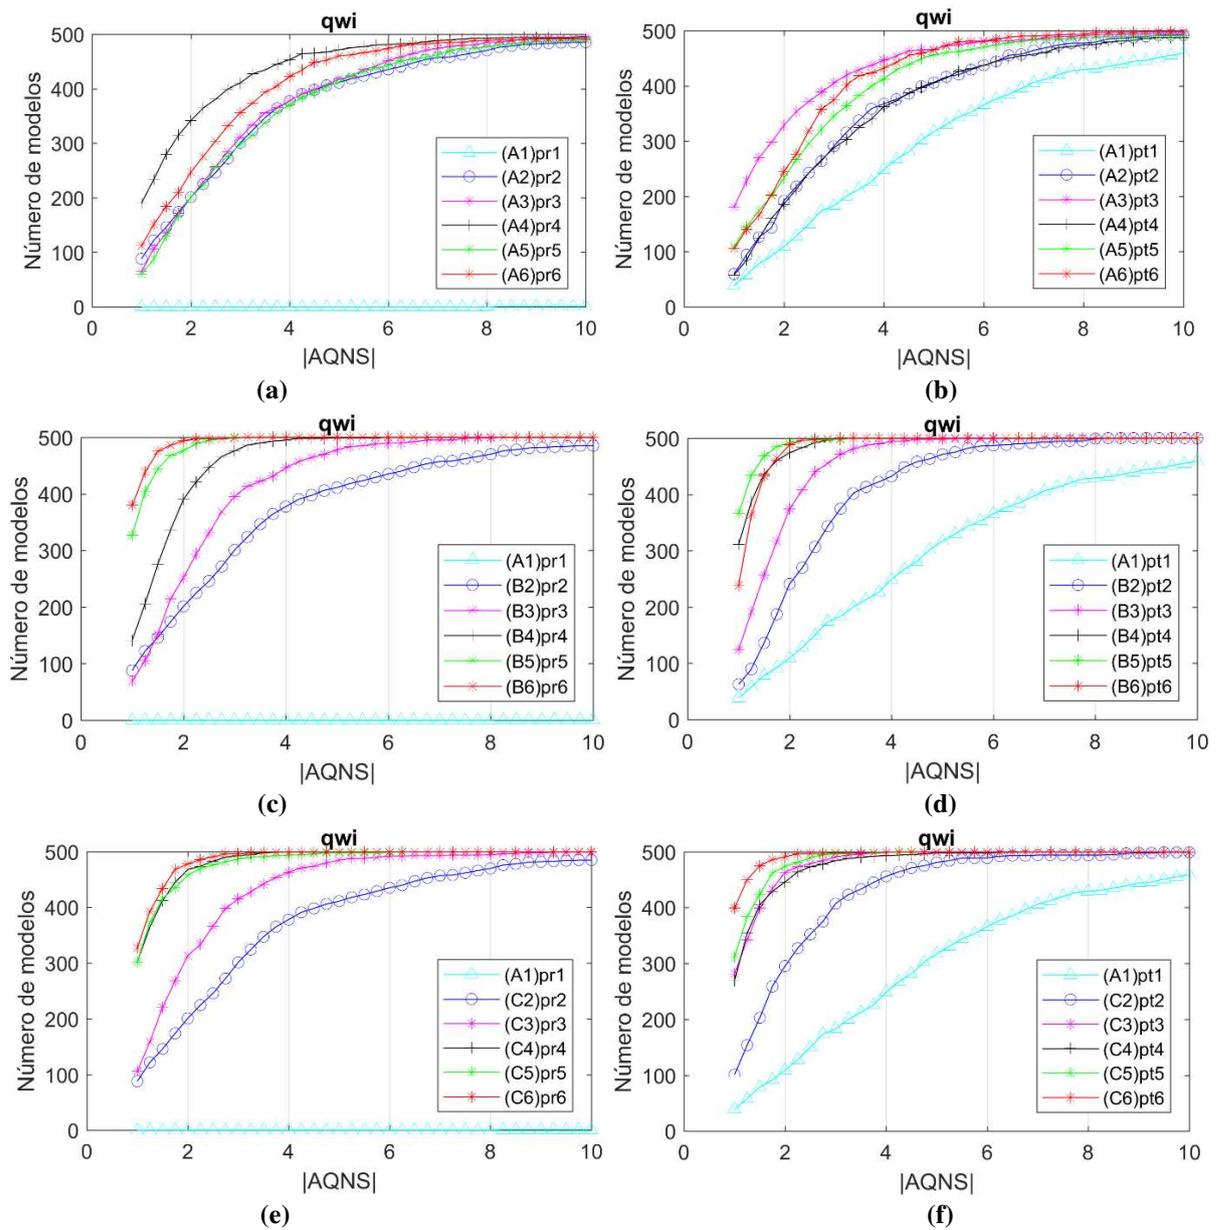


Figura A. 3: Filtragem de modelos para a q_{wi} das abordagens A, B e C com base no $|AQNS|$: (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.

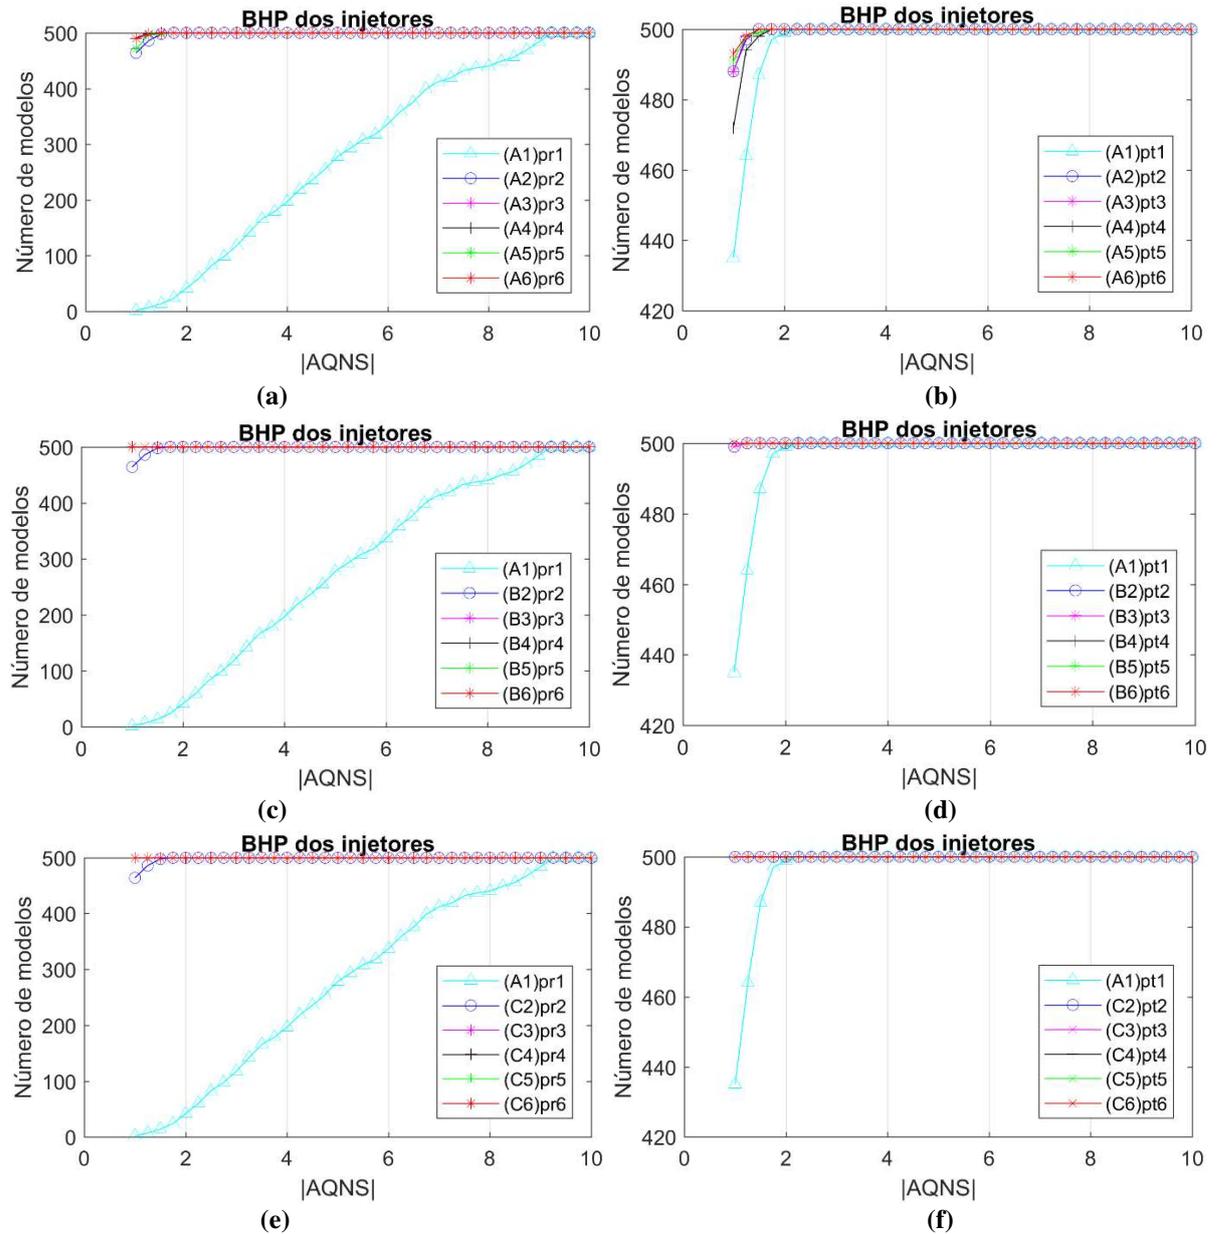


Figura A. 4: Filtragem de modelos para o BHP dos injetores das abordagens A, B e C com base no |AQNS|: (a), (c) e (e) a priori e (b), (d) e (f) a posteriori.

APÊNDICE B – GRÁFICOS DE AQNS

A seguir são apresentados os gráficos de AQNS do resultado a priori e a posteriori da q_0 , do BHP dos produtores, da q_{wi} e do BHP dos injetores para as três abordagens (A, B e C).

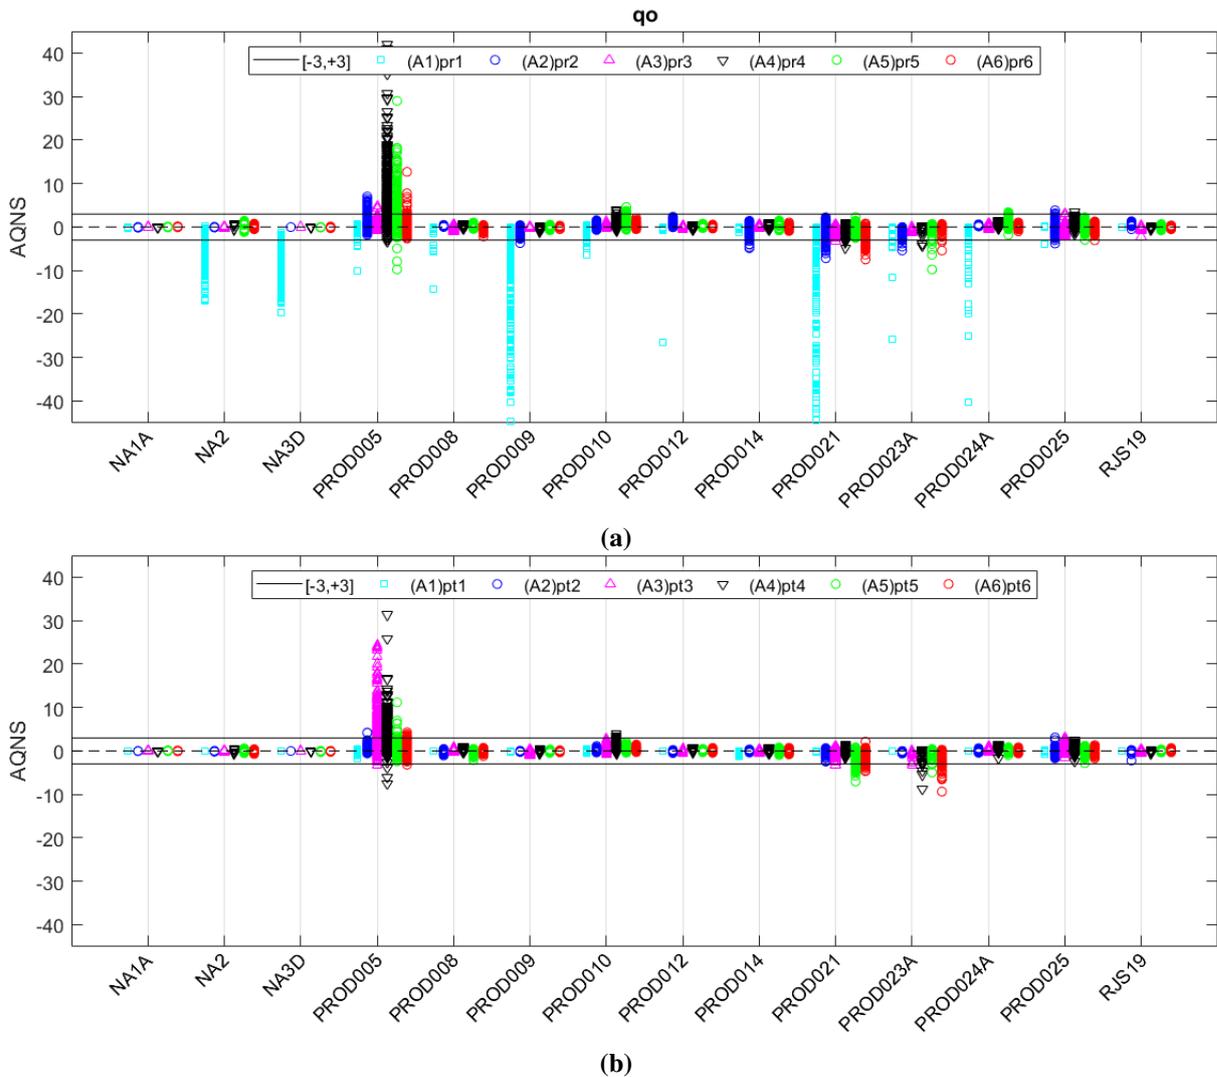


Figura B. 1: AQNS de q_0 da Abordagem A: a priori (a) e a posteriori (b).

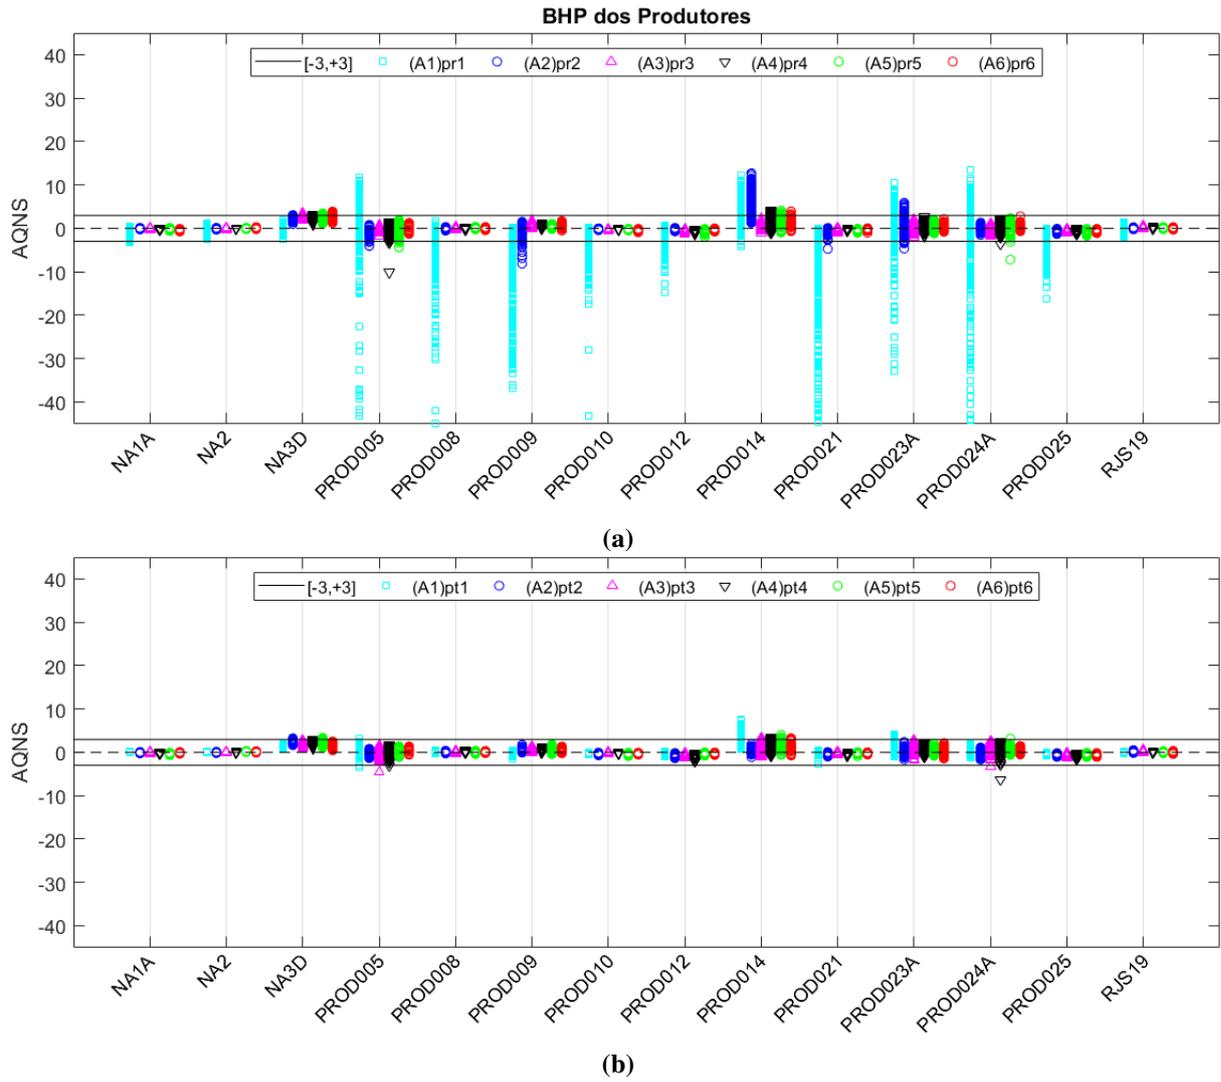


Figura B. 2: AQNS de BHP dos produtores da Abordagem A: a priori (a) e a posteriori (b).

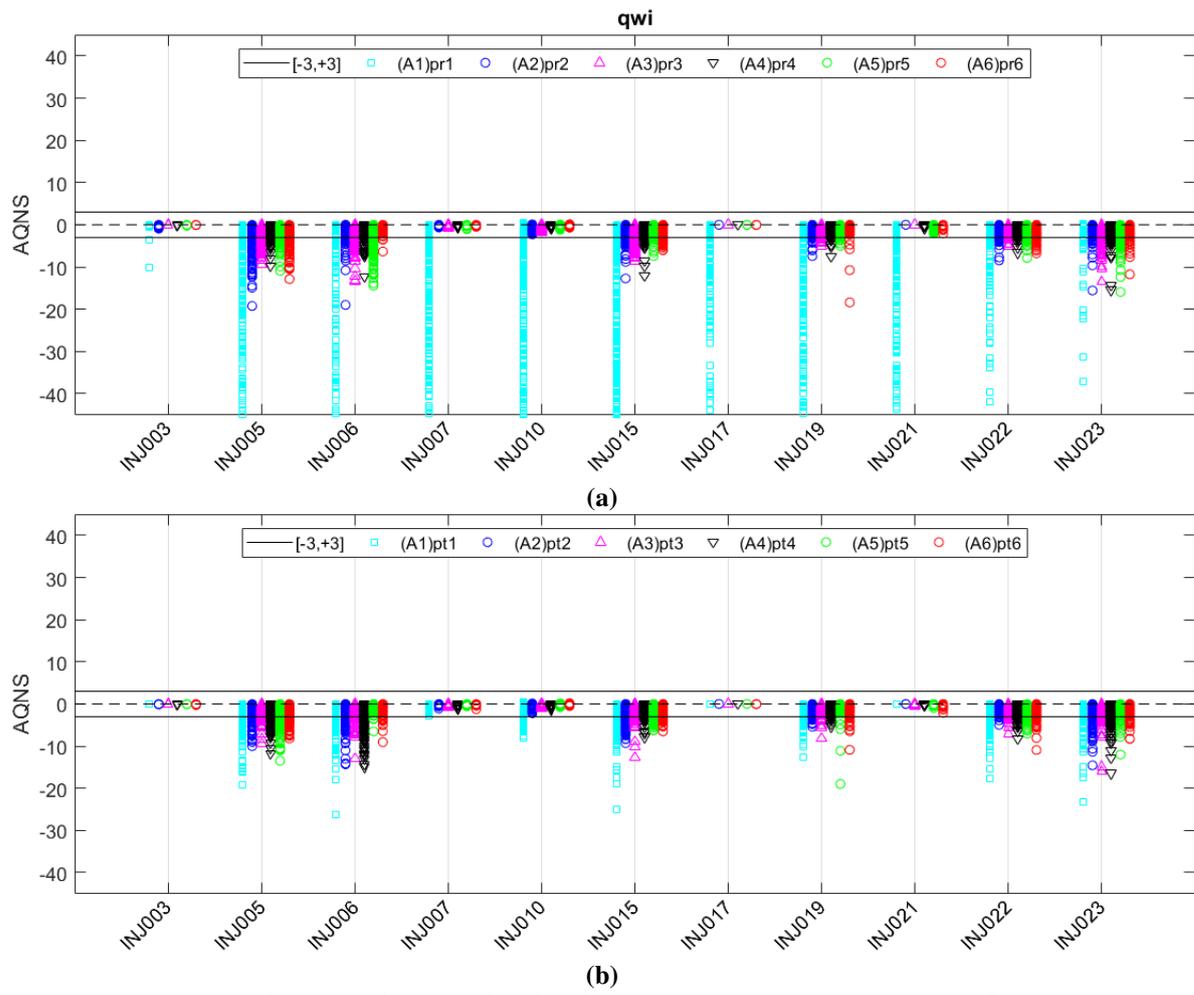


Figura B. 3: AQNS de q_{wi} da Abordagem A: a priori (a) e a posteriori (b).

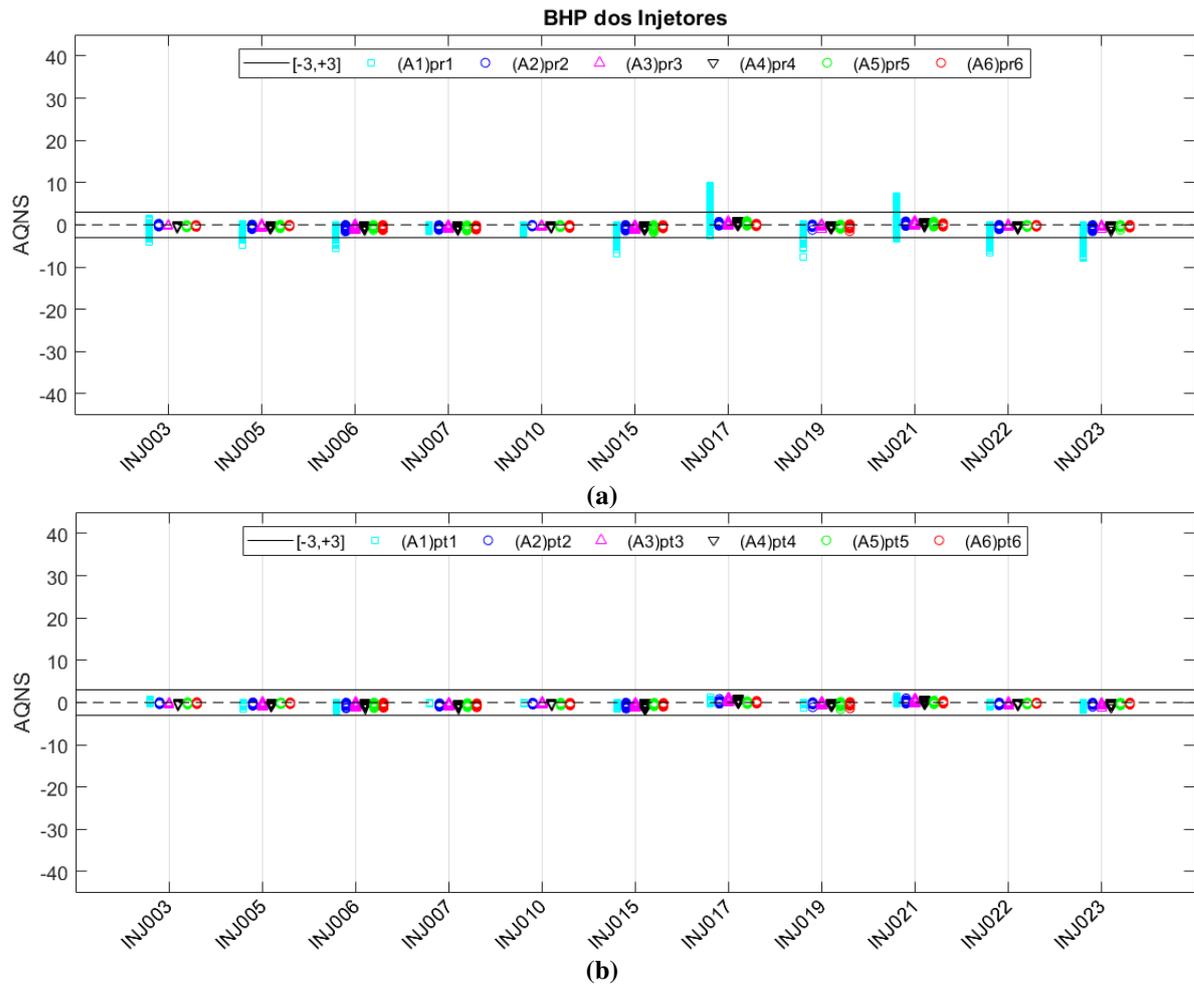


Figura B. 4: AQNS de q_{wi} da Abordagem A: a priori (a) e a posteriori (b).

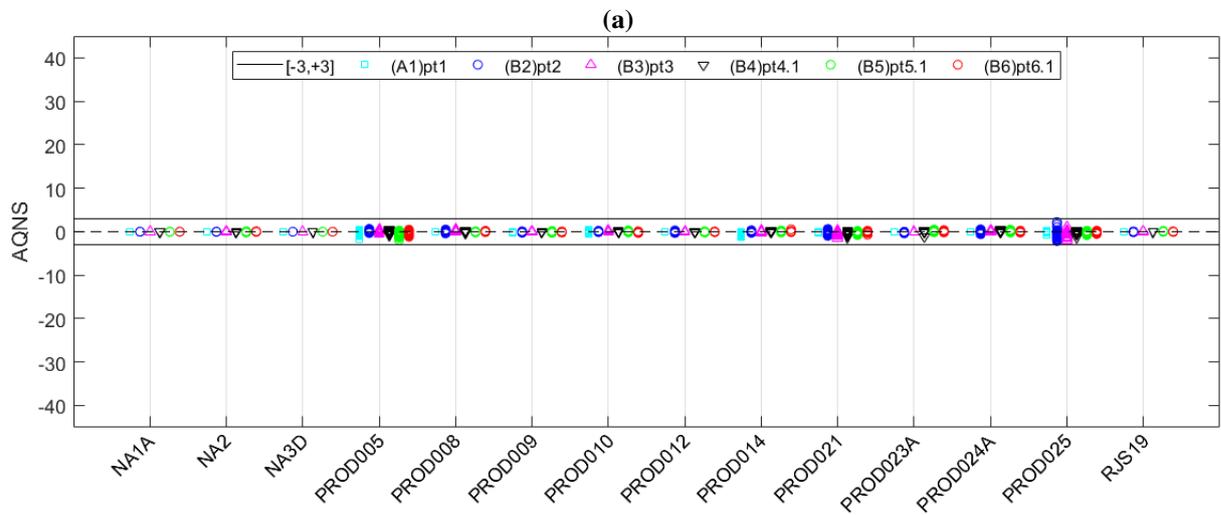
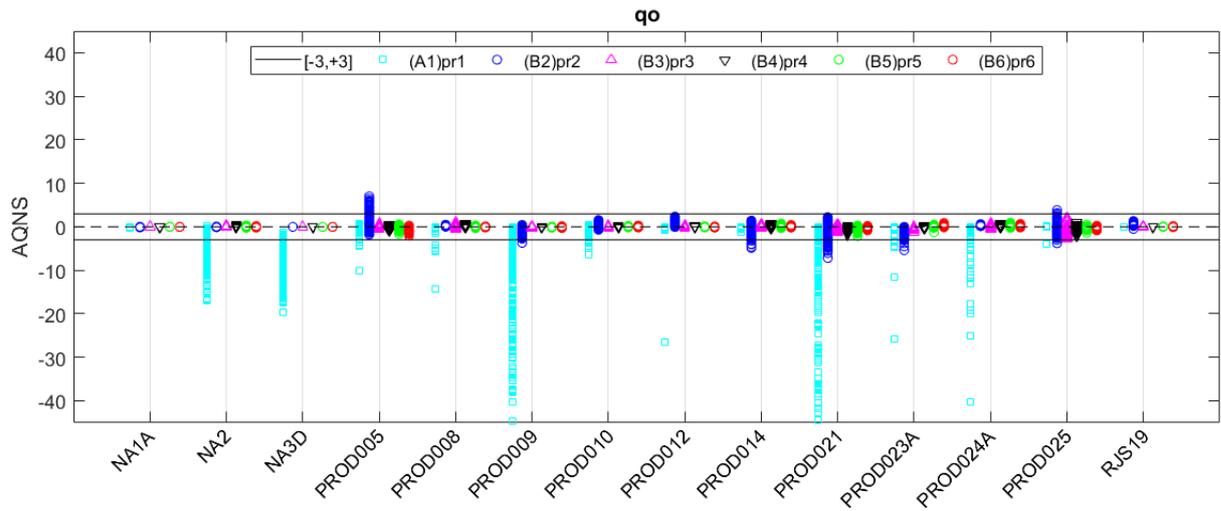


Figura B. 5: AQNS de q_0 da Abordagem B: a priori (a) e a posteriori (b).

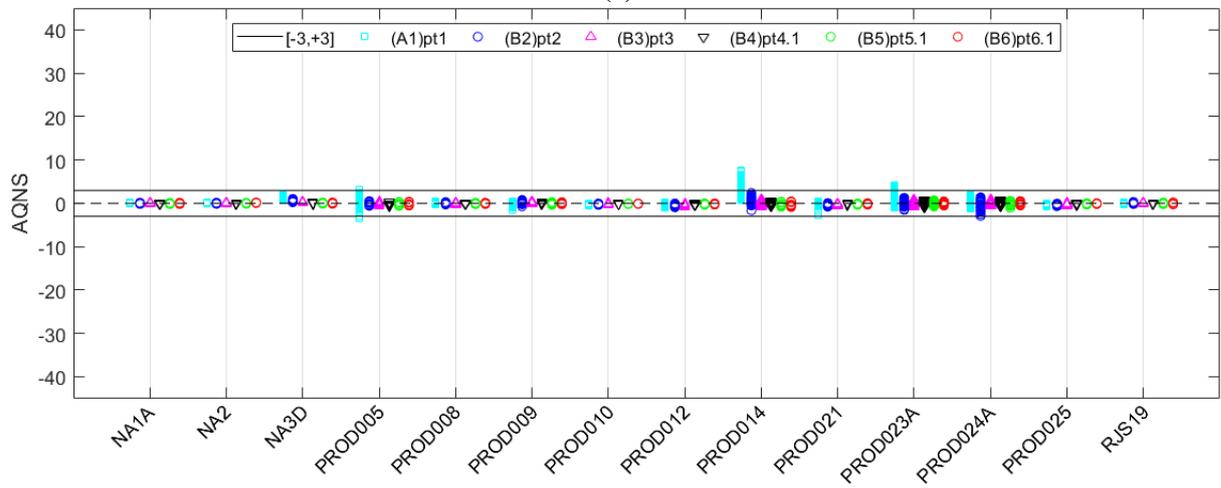
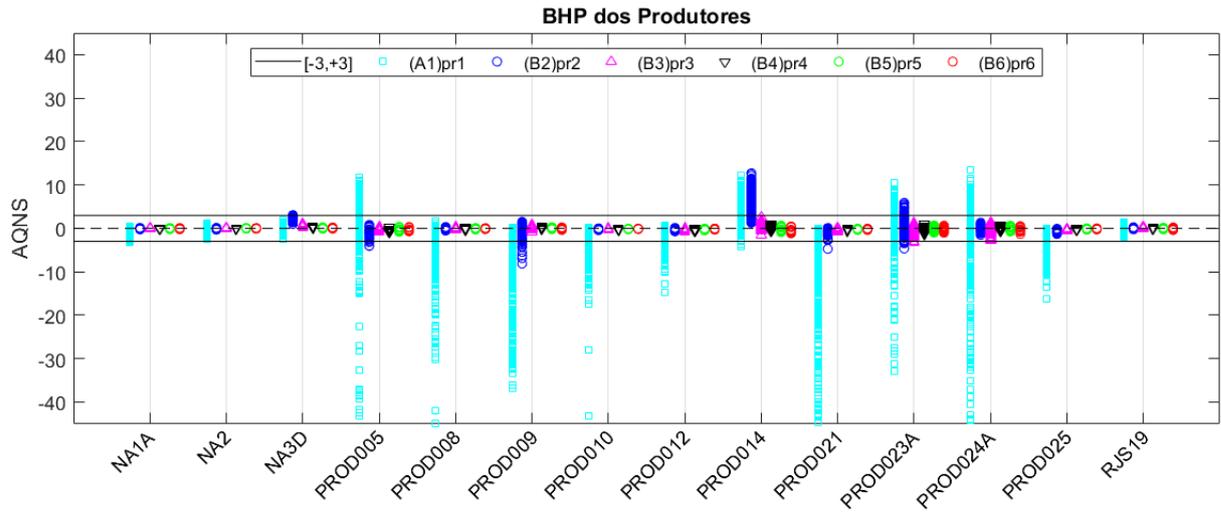


Figura B. 6: AQNS de BHP dos produtores da Abordagem B: a priori (a) e a posteriori (b).

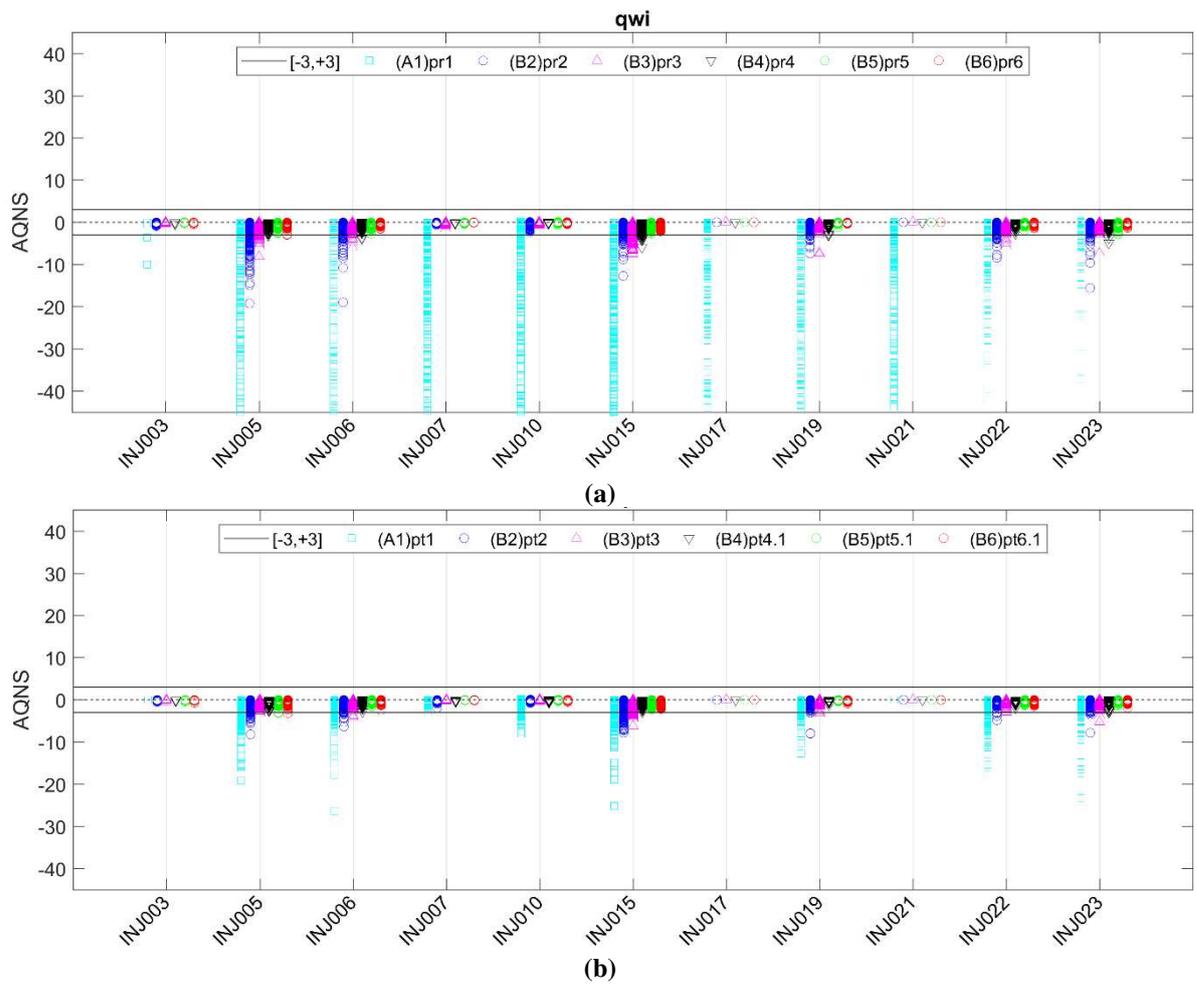


Figura B. 7: AQNS de q_{wi} da Abordagem B: a priori (a) e a posteriori (b).

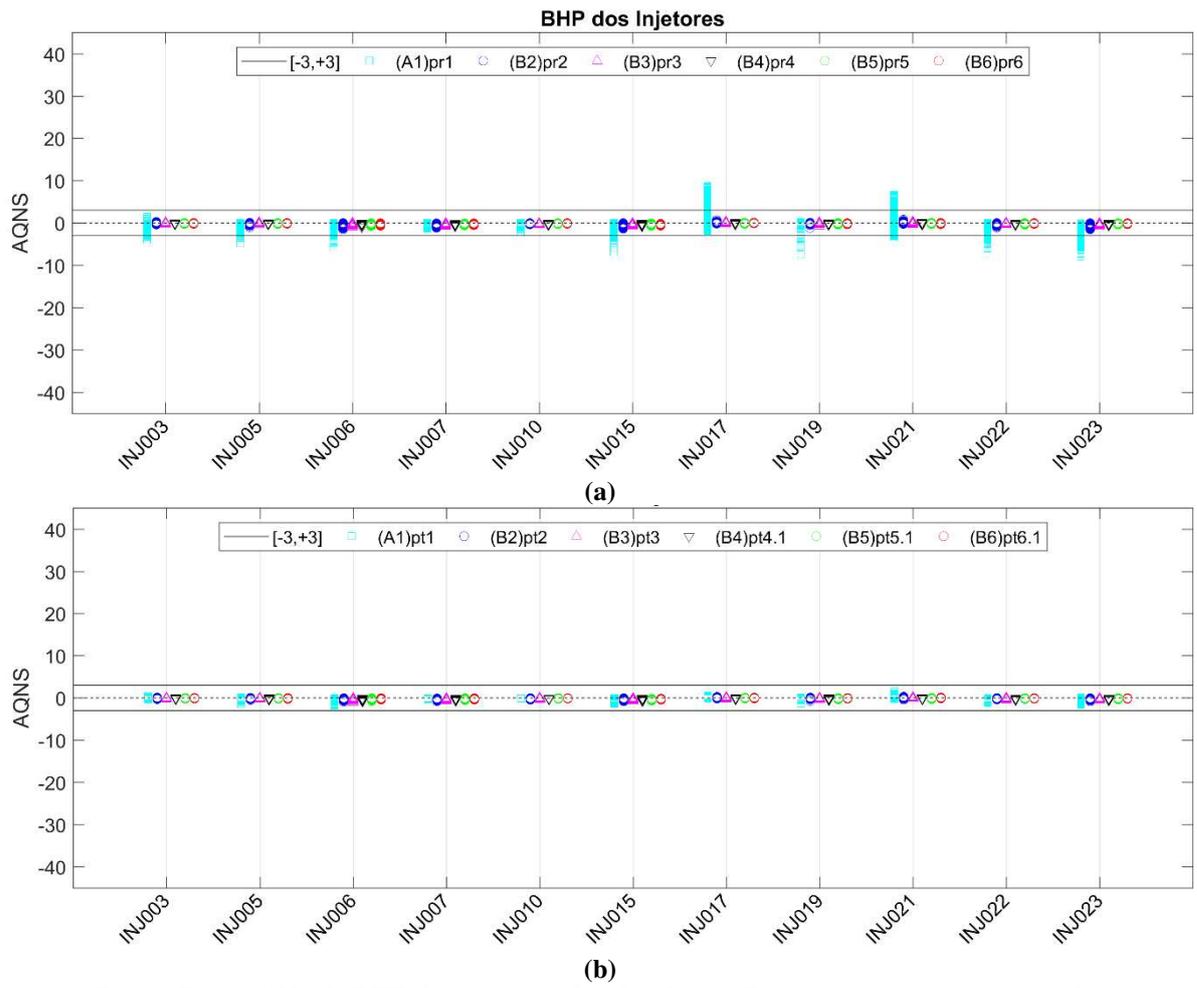


Figura B. 8: AQNS de BHP dos injetores da Abordagem B: a priori (a) e a posteriori (b).

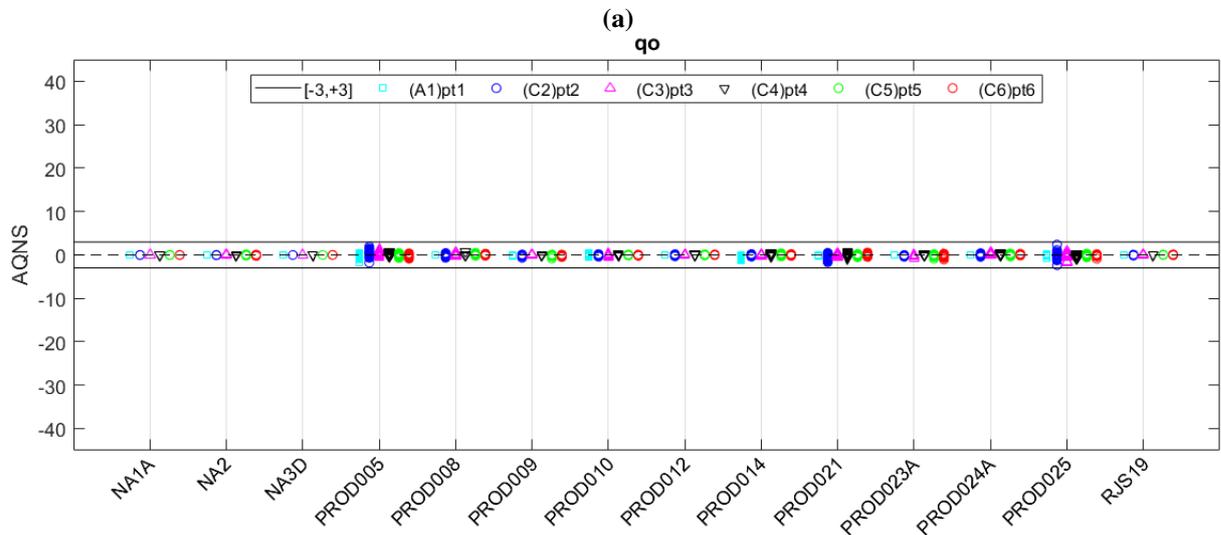
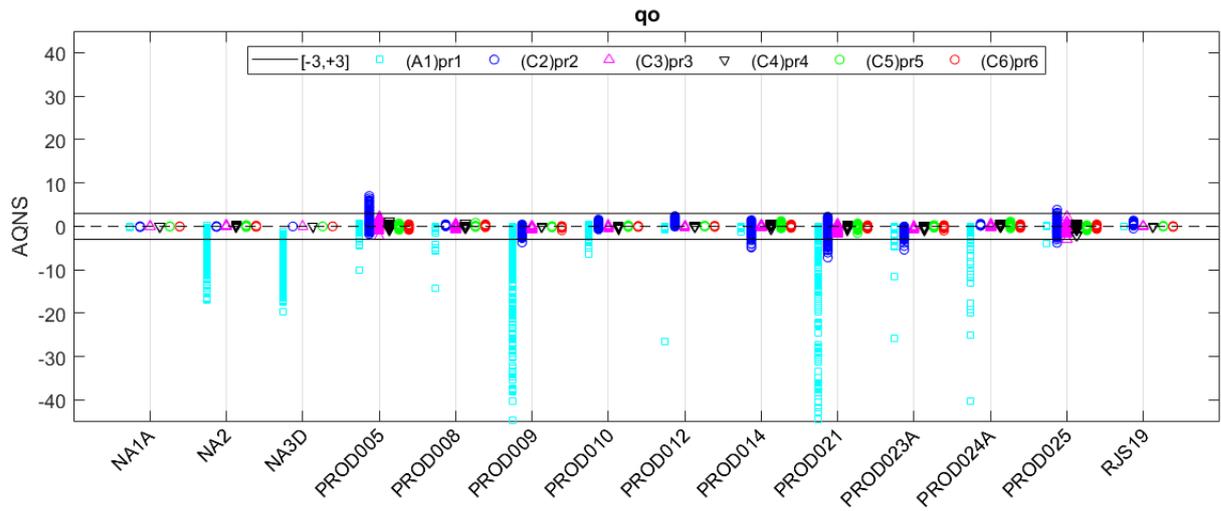


Figura B. 9: AQNS de q_0 da Abordagem C: a priori (a) e a posteriori (b).

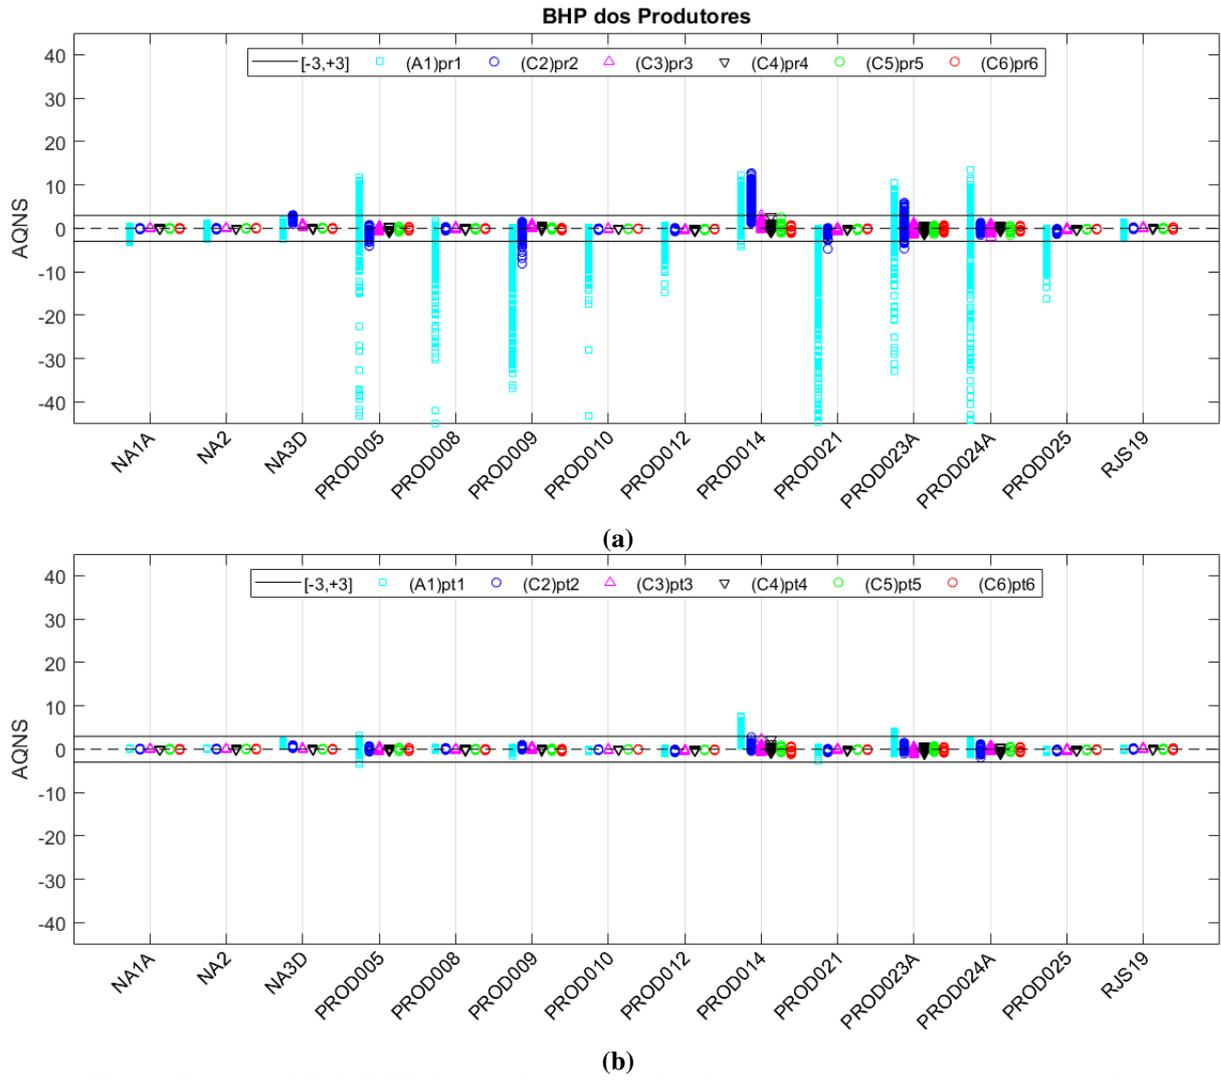
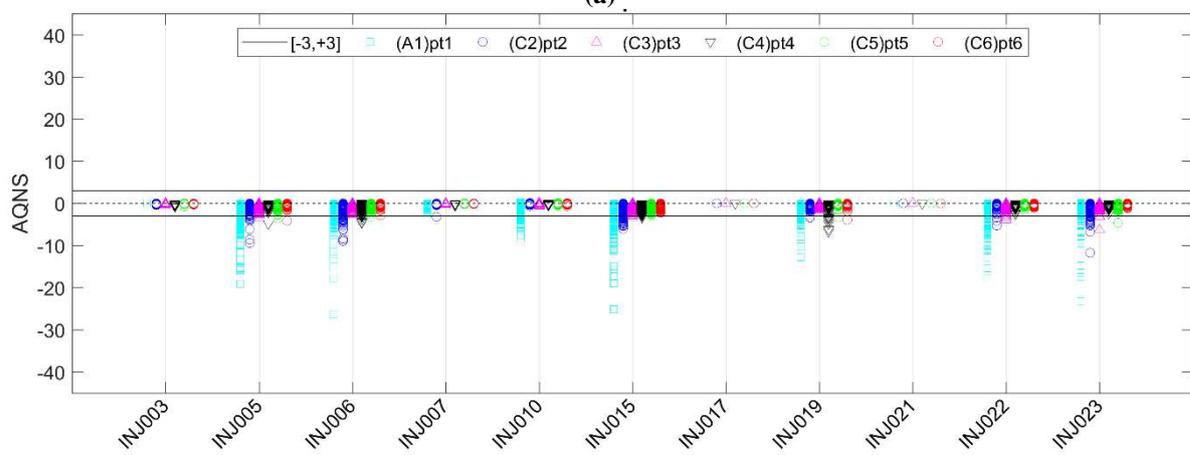
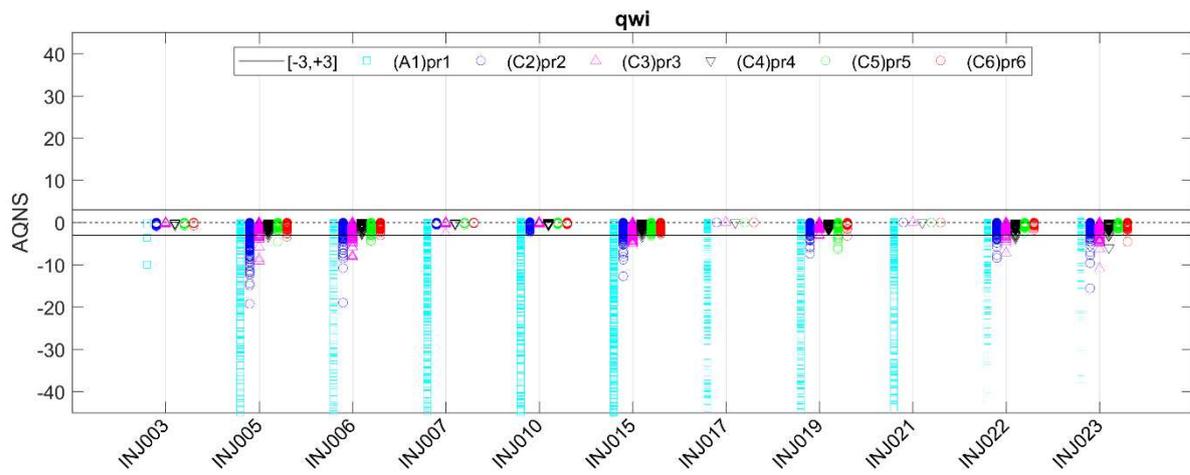


Figura B. 10: AQNS de BHP dos produtores da Abordagem C: a priori (a) e a posteriori (b).



(b)
Figura B. 11: AQNS de q_{wi} da Abordagem C: a priori (a) e a posteriori (b).

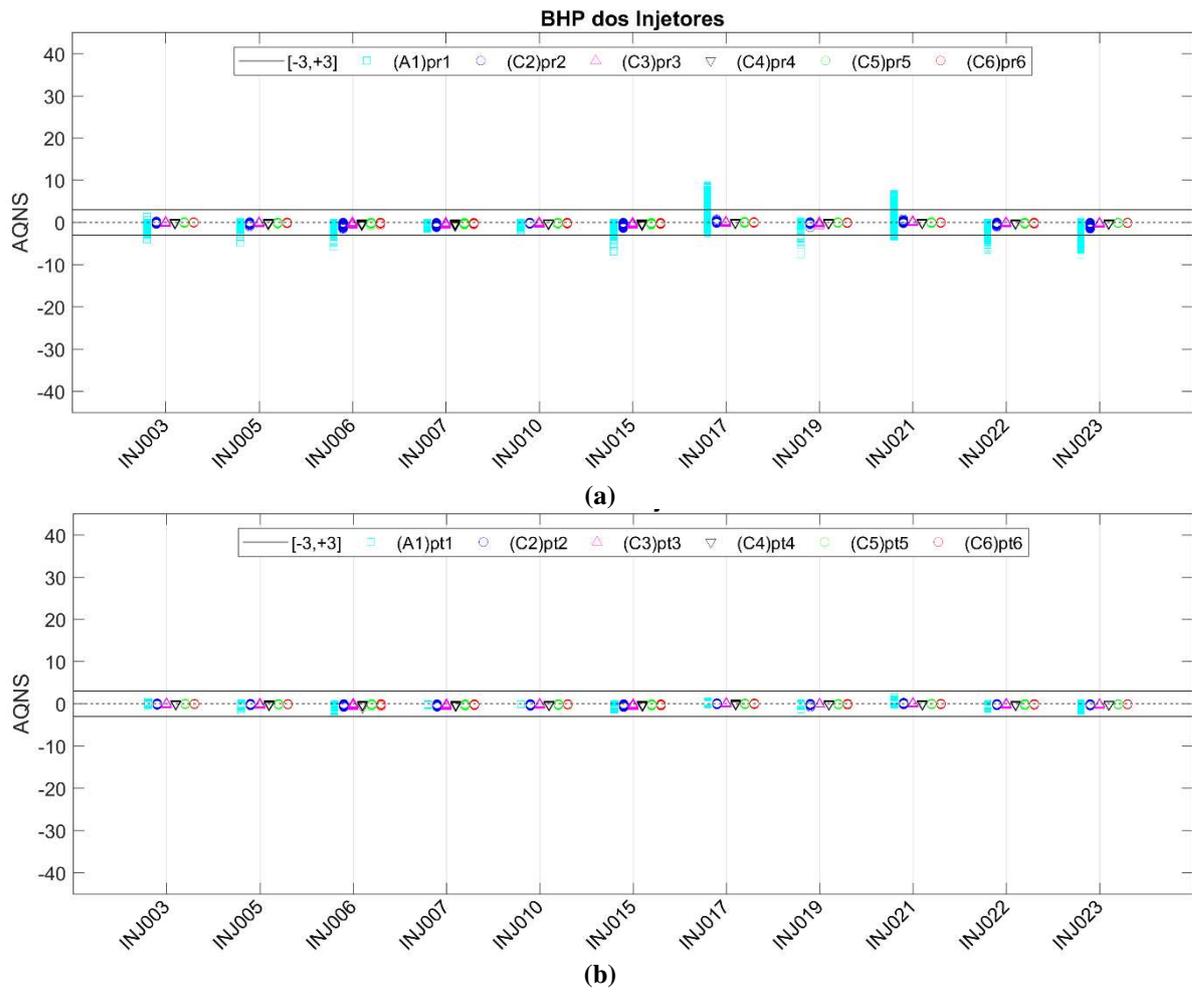


Figura B. 12: AQNS de BHP dos injetores da Abordagem C: a priori (a) e a posteriori (b).