



Vitor Hespanhol Côrtes

**Assimilação de dados integrada a técnicas de
tradução imagem-imagem aplicada a modelos
de reservatórios**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Informática, do Departamento de Informática da PUC-Rio.

Orientador: Prof. Hélio Côrtes Vieira Lopes

Rio de Janeiro
Abril de 2023



Vitor Hespagnol Côrtes

**Assimilação de dados integrada a técnicas de
tradução imagem-imagem aplicada a modelos
de reservatórios**

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Informática da PUC-Rio. Aprovada pela Comissão Examinadora abaixo:

Prof. Hélio Côrtes Vieira Lopes

Orientador

Departamento de Informática – PUC-Rio

Prof. Abelardo Borges Barreto Junior

Departamento de Engenharia Mecânica – PUC-Rio

Dr. Alexandre Anozé Emerick

Petrobras

Rio de Janeiro, 18 de Abril de 2023

Todos os direitos reservados. A reprodução, total ou parcial do trabalho, é proibida sem a autorização da universidade, do autor e do orientador.

Vitor Hespanhol Côrtes

Graduado em Engenharia de Telecomunicações pela Universidade Federal Fluminense em 2006. Possui especialização *lato sensu* em Engenharia de Petróleo e Gás Natural, realizado pelo Sistema Educacional Corporativo da Petrobras (2009), e especialização *lato sensu* em Ciência de Dados pelo programa *Business Intelligence Master* do Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro, concluída em 2018.

Ficha Catalográfica

Côrtes, Vitor Hespanhol

Assimilação de dados integrada a técnicas de tradução imagem-imagem aplicada a modelos de reservatórios / Vitor Hespanhol Côrtes; orientador: Hélio Côrtes Vieira Lopes. – 2023.

144 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Informática, 2023.

Inclui referências bibliográficas.

1. Informática – Teses. 2. Assimilação de dados. 3. Aprendizado profundo. 4. Ajuste de histórico. 5. Tradução imagem-imagem. 6. ES-MDA. 7. I2I. 8. Reservatórios. 9. Filtro de Kalman. I. Lopes, Hélio. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

Aos meus pais,
Fernando e Maria Helena,
e ao meu irmão, Lucas.

Agradecimentos

Agradeço a minha família por todo carinho, apoio, incentivo e compreensão nos momentos de ausência, cuja inspiração e amor incondicional são os verdadeiros propulsores, não somente desta breve jornada de estudos que aqui se completa, mas de toda a minha caminhada ao longo da vida.

Aos meus amigos, por todo afeto, incentivos ou mesmo uma simples conversa, muitas vezes à distância, às quais foram fundamentais para que pudesse superar os desafios e momentos difíceis.

Ao meu orientador, Doutor Hélio Lopes, por ter me guiado durante a pesquisa com seu profundo conhecimento e sabedoria, não se restringindo apenas aos ensinamentos e ao aconselhamento assertivo, mas sempre demonstrando manifestações de estímulo e amizade.

Aos colegas de curso, por toda amizade, parceria, troca de experiências e aprendizado conjunto ao longo desta jornada, tornando mais simples e agradáveis as tarefas a serem realizadas.

A todos os professores, pelos ensinamentos, paciência e disponibilidade, sempre estimulando a evolução do meu conhecimento e contribuindo, portanto, para meu amadurecimento acadêmico.

A todos os funcionários do Departamento de Informática, pela dedicação e atenção que me foram prestadas sempre que precisei de apoio.

Aos participantes da Comissão Examinadora, cujas contribuições proporcionaram maior profundidade e clareza ao trabalho.

À Petrobras, pela oportunidade de me dedicar a este estudo, além de ter me proporcionado trabalhar com os geólogos Alisson Silva e Thaís Moreira, aos quais também deixo um agradecimento especial por terem colaborado nas discussões de geologia durante a pesquisa.

Por fim, à PUC-Rio e à CAPES, pelas isenções concedidas e pelo fomento à pesquisa acadêmica, permitindo que este trabalho tenha sido realizado. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Côrtes, Vitor Hespanhol; Lopes, Hélio. **Assimilação de dados integrada a técnicas de tradução imagem-imagem aplicada a modelos de reservatórios**. Rio de Janeiro, 2023. 144p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

A incorporação de dados de produção a modelos de reservatórios é uma etapa fundamental para se estimar adequadamente a recuperação de uma jazida de petróleo e, na última década, o método *ensemble smoother with multiple data assimilation* (ES-MDA) tem se destacado dentre as estratégias disponíveis para realizar tal tarefa. Entretanto, este é um método que apresenta melhores resultados quando os parâmetros a serem ajustados no modelo são caracterizados por uma distribuição de probabilidades próxima à gaussiana, apresentando um desempenho reduzido ao lidar com o ajuste de parâmetros categóricos, como por exemplo as fácies geológicas. Uma proposta para lidar com esse problema é recorrer a redes de aprendizado profundo, em particular redes para tradução imagem-imagem (I2I), valendo-se da analogia existente entre a representação matricial de imagem e a estrutura em malha das propriedades de um modelo de reservatórios. Assim, é possível adaptar a arquitetura de redes I2I disponíveis e treiná-las para, a partir de uma matriz de parâmetros contínuos que serão ajustados pelo método ES-MDA (como porosidade e permeabilidade), gerar a representação matricial do parâmetro categórico correspondente (fácies), de forma similar à tarefa de segmentação semântica no contexto de imagens. Portanto, o parâmetro categórico seria atualizado de maneira indireta pelo método ES-MDA, sendo a sua reconstrução realizada pela rede I2I.

Palavras-chave

Assimilação de dados; Aprendizado profundo; Ajuste de histórico; Tradução imagem-imagem; ES-MDA; I2I; Reservatórios; Filtro de Kalman.

Abstract

Côrtes, Vitor Hespagnol; Lopes, Hélio (Advisor). **Data assimilation integrated with image-to-image translation networks applied to reservoir models**. Rio de Janeiro, 2023. 144p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Reservoir model data assimilation is a key step to properly estimate the final recovery of an oil field and, in the last decade, the ensemble smoother with multiple data assimilation method (ES-MDA) has stood out among all available strategies to perform this task. However, this method achieves better results when model parameters are described by an approximately Gaussian distribution and hence presents reduced performance when dealing with categorical parameters, such as geological facies. An alternative to deal with this issue is to adopt a deep learning based approach, particularly using image-to-image translation (I2I) networks and taking into account the analogy between the matrix representation of images and the reservoir model grid properties. Thus, it is possible to adapt I2I network architectures, training them to generate the categorical parameter (facies) from its correlated continuous properties modified by the ES-MDA method (such as porosity and permeability), similar to semantic segmentation tasks in an image translation context. Therefore, the categorical parameter would be indirectly updated by the ES-MDA method, with its reconstruction carried out by the I2I network.

Keywords

Data assimilation; Deep learning; History matching; Image-to-image translation; ES-MDA; I2I; Reservoir; Kalman filter.

Sumário

1	Introdução	22
1.1	Definição do Problema	23
1.2	Resumo dos Capítulos	25
2	Ajuste de Histórico de Modelos de Reservatórios	27
2.1	Métodos de Ajuste Assistido de Histórico	28
2.2	Métodos Baseados em Filtro de Kalman	30
2.2.1	<i>Ensemble Smoother with Multiple Data Assimilation (ES-MDA)</i>	31
2.2.2	Localização da Covariância	33
3	Tradução Imagem-imagem	34
3.1	Arquiteturas <i>Encoder-decoder</i>	35
3.2	Arquiteturas Generativas Adversárias	37
3.3	Redes Generativas para Tradução Imagem-imagem	39
3.3.1	Rede pix2pix	43
4	Metodologia de Assimilação de Dados Integrada à Tradução Imagem-imagem	46
4.1	Analogia entre Imagem e Modelo de Reservatórios	47
4.2	Metodologia Proposta	48
5	Aplicação da Metodologia	51
5.1	Construção dos Casos de Estudo	51
5.1.1	Modelo de Reservatórios	51
5.1.2	Realizações Geológicas	53
5.1.3	Mudança de Escala	57
5.1.4	Casos de Estudo	59
5.1.5	Representação das Propriedades Geológicas para a Rede I2I	60
5.2	Métricas de Avaliação	61
5.2.1	Desvio Médio Normalizado dos Dados de Históricos	62
5.2.2	Distância L1	62
5.2.3	SSIM	62
5.2.4	Matriz de Confusão	63
5.3	Treinamento das Redes de Tradução I2I	64
5.4	Assimilação de Dados	68
5.4.1	Análise dos Dados de Produção	69
5.4.2	Análise dos Modelos	74
5.4.2.1	Caso de Estudo 1A	78
5.4.2.2	Caso de Estudo 1B	82
5.4.2.3	Caso de Estudo 2A	91
5.4.2.4	Caso de Estudo 2B	96
6	Conclusões e Recomendações	106
	Referências bibliográficas	110

A	Algoritmo ES-MDA	116
B	Matriz de Localização da Covariância	118
C	Redes para Tradução Imagem-imagem	120
D	Curvas de Permeabilidade Relativa	122
E	Resultados do Ajuste de Histórico	125
E.1	Caso de Estudo 1A	125
E.2	Caso de Estudo 1B	130
E.3	Caso de Estudo 2A	135
E.4	Caso de Estudo 2B	140

Lista de Figuras

Figura 3.1	Rede neural convolucional [25]	35
Figura 3.2	Diagrama de uma rede <i>encoder-decoder</i> .	36
Figura 3.3	Diagrama da rede U-Net	37
Figura 3.4	Estrutura geral de uma CGAN: módulo discriminador aprende a classificar se uma imagem sintetizada pelo gerador é real (b) ou falsa (a), enquanto o gerador tenta enganar o discriminador.	39
Figura 3.5	Tradução imagem-imagem unimodal: (a) síntese de imagem, (b) colorização, (c) segmentação semântica e (d) transferência de estilo [17, 62].	41
Figura 3.6	Tradução imagem-imagem multimodal [63].	41
Figura 3.7	Tradução imagem-imagem multidomínio [56].	42
Figura 3.8	Estrutura básica das redes I2I: (a) domínios pareados unimodal, (b) domínios pareados multimodal, (c) multidomínio unimodal e (b) multidomínio multimodal.	43
Figura 3.9	Diagrama da rede pix2pix.	44
Figura 4.1	Analogia da representação em malha entre imagens e modelos de reservatórios	48
Figura 4.2	Metodologia para assimilação de dados a modelos de reservatórios integrada a redes de tradução I2I.	49
Figura 5.1	Modelo de reservatórios utilizado no estudo (versão de 3 camadas): (a) visão tridimensional; (b) visão em mapa.	52
Figura 5.2	Analogia para construção dos modelos geológicos: (a) Delta do rio Yukon, Alaska (EUA) [47]; (b) Modelo conceitual do sistema deposicional deltaico, com canais distributários (cenário 1) e lobos deltaicos (cenário 2) [36].	54
Figura 5.3	Imagens de treinamento por camada para modelagem geológica das fácies do Cenário 1 através do método MPS.	55
Figura 5.4	Mapas de tendência de fácies por camada para modelagem geológica do Cenário 2 através do método TGS	56
Figura 5.5	Histograma das propriedades petrofísicas do cenário 01.	57
Figura 5.6	Histograma das propriedades petrofísicas do cenário 02.	57
Figura 5.7	Mudança de escala (<i>upscaling</i>) em modelos de reservatórios (adaptado de [49]).	58
Figura 5.8	Métodos de (<i>upscaling</i>) por propriedade.	59
Figura 5.9	Amostras das realizações de fácies para cada caso de estudo.	60
Figura 5.10	Amostras das realizações de porosidade para cada caso de estudo.	60
Figura 5.11	Amostras das realizações de permeabilidade horizontal para cada caso de estudo.	60
Figura 5.12	Representação matricial das propriedades petrofísicas para a rede: (a) modelo com <i>upscaling</i> ; (b) modelo refinado.	61
Figura 5.13	Matriz de confusão	63

Figura 5.14	Distância L1 média da base de validação ao longo das épocas de treinamento	65
Figura 5.15	<i>Boxplot</i> da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 1A	66
Figura 5.16	<i>Boxplot</i> da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 1B	66
Figura 5.17	<i>Boxplot</i> da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 2A	66
Figura 5.18	<i>Boxplot</i> da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 2B	67
Figura 5.19	Comparação entre as imagens de fácies da base de teste (<i>ground truth</i>) e suas respectivas imagens traduzida pela rede.	68
Figura 5.20	<i>Boxplot</i> do desvio médio normalizado dos dados de históricos para o caso de estudo 1A.	70
Figura 5.21	<i>Boxplot</i> do desvio médio normalizado dos dados de históricos para o caso de estudo 1B.	70
Figura 5.22	<i>Boxplot</i> do desvio médio normalizado dos dados de históricos para o caso de estudo 2A.	71
Figura 5.23	<i>Boxplot</i> do desvio médio normalizado dos dados de históricos para o caso de estudo 2B.	71
Figura 5.24	Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “ <i>Producer1</i> ” para o caso de estudo 1A.	72
Figura 5.25	Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “ <i>Producer1</i> ” para o caso de estudo 1B.	72
Figura 5.26	Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “ <i>Producer1</i> ” para o caso de estudo 2A.	73
Figura 5.27	Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “ <i>Producer1</i> ” para o caso de estudo 2B.	73
Figura 5.28	Métricas para comparação do modelos de fácies <i>prior</i> e <i>posterior</i> com o reservatório de referência do caso de estudo 1A: (a) Distância L1; (b) SSIM.	74
Figura 5.29	Métricas para comparação do modelos de fácies <i>prior</i> e <i>posterior</i> com o reservatório de referência do caso de estudo 1B: (a) Distância L1; (b) SSIM.	75
Figura 5.30	Métricas para comparação do modelos de fácies <i>prior</i> e <i>posterior</i> com o reservatório de referência do caso de estudo 2A: (a) Distância L1; (b) SSIM.	75
Figura 5.31	Métricas para comparação do modelos de fácies <i>prior</i> e <i>posterior</i> com o reservatório de referência do caso de estudo 2B: (a) Distância L1; (b) SSIM.	76
Figura 5.32	Matriz de confusão do caso de estudo 1A.	76
Figura 5.33	Matriz de confusão do caso de estudo 1B.	77
Figura 5.34	Matriz de confusão do caso de estudo 2A.	77
Figura 5.35	Matriz de confusão do caso de estudo 2B.	77
Figura 5.36	Mapas de fácies do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	79

Figura 5.37	Mapas de porosidade do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	79
Figura 5.38	Mapas de permeabilidade horizontal do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	80
Figura 5.39	Mapas de permeabilidade vertical do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	80
Figura 5.40	Mapas de saturação de água do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	81
Figura 5.41	Mapas de saturação de gás do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	81
Figura 5.42	Mapas de pressão do caso de estudo 1A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	82
Figura 5.43	Mapas de fácies da camada 01 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	83
Figura 5.44	Mapas de fácies da camada 02 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	83
Figura 5.45	Mapas de fácies da camada 03 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	84
Figura 5.46	Mapas de porosidade da camada 01 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	84
Figura 5.47	Mapas de porosidade da camada 02 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	85
Figura 5.48	Mapas de porosidade da camada 03 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	85
Figura 5.49	Mapas de permeabilidade horizontal da camada 01 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	86
Figura 5.50	Mapas de permeabilidade horizontal da camada 02 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	86

Figura 5.51	Mapas de permeabilidade horizontal da camada 03 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	87
Figura 5.52	Mapas de saturação de água da camada 01 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	87
Figura 5.53	Mapas de saturação de água da camada 02 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	88
Figura 5.54	Mapas de saturação de água da camada 03 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	88
Figura 5.55	Mapas de saturação de gás da camada 01 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	89
Figura 5.56	Mapas de saturação de gás da camada 02 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	89
Figura 5.57	Mapas de saturação de gás da camada 03 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	90
Figura 5.58	Mapas de pressão da camada 01 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	90
Figura 5.59	Mapas de pressão da camada 02 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	91
Figura 5.60	Mapas de pressão da camada 03 do caso de estudo 1B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	91
Figura 5.61	Histogramas da porosidade de uma das células ao longo dos 200 modelos <i>a priori</i> e <i>a posteriori</i> : (a) caso de estudo 1A; (b) caso de estudo 2A.	92
Figura 5.62	Mapas de fácies do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	93
Figura 5.63	Mapas de porosidade do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	93

Figura 5.64	Mapas de permeabilidade horizontal do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	94
Figura 5.65	Mapas de permeabilidade vertical do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	94
Figura 5.66	Mapas de saturação de água do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	95
Figura 5.67	Mapas de saturação de gás do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	95
Figura 5.68	Mapas de pressão do caso de estudo 2A comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	96
Figura 5.69	Mapas de fácies da camada 01 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	96
Figura 5.70	Mapas de fácies da camada 02 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	97
Figura 5.71	Mapas de fácies da camada 03 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	97
Figura 5.72	Mapas de porosidade da camada 01 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	98
Figura 5.73	Mapas de porosidade da camada 02 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	98
Figura 5.74	Mapas de porosidade da camada 03 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	99
Figura 5.75	Mapas de permeabilidade horizontal da camada 01 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	99
Figura 5.76	Mapas de permeabilidade horizontal da camada 02 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	100
Figura 5.77	Mapas de permeabilidade horizontal da camada 03 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	100

Figura 5.78	Mapas de saturação de água da camada 01 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	101
Figura 5.79	Mapas de saturação de água da camada 02 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	101
Figura 5.80	Mapas de saturação de água da camada 03 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	102
Figura 5.81	Mapas de saturação de gás da camada 01 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	102
Figura 5.82	Mapas de saturação de gás da camada 02 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	103
Figura 5.83	Mapas de saturação de gás da camada 03 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	103
Figura 5.84	Mapas de pressão da camada 01 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	104
Figura 5.85	Mapas de pressão da camada 02 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	104
Figura 5.86	Mapas de pressão da camada 03 do caso de estudo 2B comparando o reservatório de referência (<i>ground truth</i>) com três das realizações <i>a priori</i> (superior) e suas respectivas realizações <i>a posteriori</i> (inferior).	105
Figura B.1	Localização da Covariância.	118
Figura E.1	Ajuste de histórico do caso de estudo 1A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (1/4).	125
Figura E.2	Ajuste de histórico do caso de estudo 1A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (2/4).	126

Figura E.3	Ajuste de histórico do caso de estudo 1A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (3/4).	127
Figura E.4	Ajuste de histórico do caso de estudo 1A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (4/4).	128
Figura E.5	Ajuste de histórico do caso de estudo 1A , com cada coluna representando um tipo de dado e cada linha representando dois poços injetores : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste.	129
Figura E.6	Ajuste de histórico do caso de estudo 1B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (1/4).	130
Figura E.7	Ajuste de histórico do caso de estudo 1B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (2/4).	131
Figura E.8	Ajuste de histórico do caso de estudo 1B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (3/4).	132
Figura E.9	Ajuste de histórico do caso de estudo 1B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (4/4).	133
Figura E.10	Ajuste de histórico do caso de estudo 1B , com cada coluna representando um tipo de dado e cada linha representando dois poços injetores : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste.	134
Figura E.11	Ajuste de histórico do caso de estudo 2A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (1/4).	135

Figura E.12	Ajuste de histórico do caso de estudo 2A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (2/4).	136
Figura E.13	Ajuste de histórico do caso de estudo 2A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (3/4).	137
Figura E.14	Ajuste de histórico do caso de estudo 2A , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (4/4).	138
Figura E.15	Ajuste de histórico do caso de estudo 2A , com cada coluna representando um tipo de dado e cada linha representando dois poços injetores : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste.	139
Figura E.16	Ajuste de histórico do caso de estudo 2B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (1/4).	140
Figura E.17	Ajuste de histórico do caso de estudo 2B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (2/4).	141
Figura E.18	Ajuste de histórico do caso de estudo 2B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (3/4).	142
Figura E.19	Ajuste de histórico do caso de estudo 2B , com cada coluna representando um tipo de dado e cada linha representando um poço produtor : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste (4/4).	143
Figura E.20	Ajuste de histórico do caso de estudo 2B , com cada coluna representando um tipo de dado e cada linha representando dois poços injetores : em vermelho são apresentados os dados observados, em cinza o conjunto de modelos <i>a priori</i> , em ciano o conjunto de modelos <i>a posteriori</i> e em azul escuro a curva do modelo com melhor ajuste.	144

Lista de Tabelas

Tabela 5.1	Parâmetros da distribuição gaussiana truncada para modelagem das propriedades petrofísicas.	56
Tabela 5.2	Casos de Estudo.	59
Tabela C.1	Redes I2I.	120
Tabela D.1	Curvas de permeabilidade relativa das fácies 1 (baixa energia).	122
Tabela D.2	Curvas de permeabilidade relativa das fácies 2 (média energia).	123
Tabela D.3	Curvas de permeabilidade relativa das fácies 3 (alta energia).	124

Lista de Abreviaturas

α – coeficiente de inflação

ε – ruído aleatório

ϕ – porosidade

\mathbf{C}_D – matriz de covariância do ruído nos dados medidos

CGAN – *Conditional Adversarial Network*

\mathbf{C}_{MS} – matriz de covariância cruzada entre os parâmetros do modelo e os dados simulados

CNN – Rede neural convolucional

\mathbf{C}_S – matriz de covariância dos dados simulados

\mathbf{d} – dados simulados a partir de um modelo de simulação \mathbf{m}

\mathbf{d}_{hist} – dados históricos representativo do reservatório de referência

E&P – Exploração e Produção de Petróleo

EnKF – *Ensemble Kalman Filter*

ES – *Ensemble Smoother*

ES-MDA – *Ensemble Smoother with Multiple Data Assimilation*

GAN – *Generative Adversarial Network*

k – permeabilidade

k_h – permeabilidade horizontal

k_v – permeabilidade vertical

\mathbf{K} – ganho de Kalman

\mathbf{m} – modelo de reservatórios

\mathbf{m}_{prior} – modelo *a priori*

\mathbf{m}_{post} – modelo *a posteriori*

$\mathbf{m}_{\mathcal{R}}$ – modelo representativo do reservatório real

MPS – *Multiple-Point Simulation*

N_a – número de iterações para assimilação de dados

N_d – número total de dados históricos

N_m – número total de modelos

N_p – número total de parâmetros em cada modelo

PSO – *Particle Swarm Optimization*

\mathbf{R}_{MD} – matriz de localização da covariância

SPE – *Society of Petroleum Engineers*

SSIM – *Structural Similarity Index Measure*

TGS – *Truncated Gaussian Simulation*

VAE – *Variational Autoencoder*

*“Em nossos raciocínios a respeito de fatos,
existem todos os graus imagináveis de
certeza. Um homem sábio, portanto, ajusta
sua crença à evidência.”*

David Hume, *Investigação sobre o entendimento humano*.

1

Introdução

O desenvolvimento de projetos na área de exploração e produção de petróleo (E&P) possui intrinsecamente um elevado grau de risco relacionado às incertezas associadas à atividade. Tais incertezas se devem às dificuldades de se conhecer fielmente as características e a distribuição espacial das heterogeneidades da jazida, podendo abranger tanto características geológicas quanto a composição dos fluidos nela contidos. Este fato, associado aos altos investimentos envolvidos, tem impacto direto na economicidade dos projetos, que deve ser criteriosamente avaliada no momento da definição do plano de exploração e ao longo da vida produtiva do reservatório.

Um reservatório de petróleo é uma acumulação em subsuperfície que possui porosidade e permeabilidade suficientes para armazenar e permitir a produção dos fluidos nela presentes (óleo, gás e/ou água), trapeados por uma rocha capeadora. Após a descoberta de um reservatório, são realizados todos os estudos necessários para definir um plano de drenagem e estimar a recuperação da jazida, avaliando-se a viabilidade econômica do projeto.

Assim, a tomada de decisão em projetos de E&P deve ser fundamentada na quantificação do impacto das incertezas de forma a realizar uma melhor previsão do comportamento futuro do reservatório. Neste contexto, a simulação de reservatórios representa um papel fundamental para o desenvolvimento de campos de petróleo, permitindo avaliar a recuperação final da jazida ao serem adotadas diferentes estratégias de exploração e proporcionando uma maior precisão na estimativa da produção do reservatório.

A construção de um modelo de reservatórios é um processo que requer um vasto conhecimento das propriedades e dos processos geológicos e petrofísicos envolvidos, que são modelados numa malha discreta de forma a representar suficientemente a complexidade do reservatório, sendo este modelo o arcabouço que suportará a solução de equações fundamentais de escoamento em meios porosos que determinarão as variações temporais de seus estados (pressões e saturações), indutores da produção dos poços, condicionados aos dados de entrada e às restrições impostas pelas condições operacionais dos sistemas de produção.

De forma geral, a caracterização e a modelagem geológica de um reservatório dependem da inferência e extrapolação de suas propriedades estáticas (como porosidade e permeabilidade) a partir de dados escassos de poços (quando comparados às dimensões do reservatório), de dados sísmicos da jazida, além de todo conhecimento conceitual disponível sobre a geologia do reservatório [19], contribuindo portanto para o alto grau de incerteza do processo e resultando em uma grande quantidade de representações possíveis.

Entretanto, ao longo da vida produtiva do reservatório, um amplo conjunto de dados dinâmicos é obtido através do monitoramento dos poços, como pressões e vazões de produção e injeção, entre outros, dados estes que trazem informações relevantes que devem ser incorporados à modelagem do reservatório de forma a gradualmente reduzir as incertezas impostas. Este processo de assimilação de dados, portanto, é uma etapa de grande importância, pois a confiabilidade da resposta de um modelo de reservatórios está diretamente associada a sua capacidade de reproduzir com fidelidade os dados históricos de produção.

Desse modo, pode-se definir o termo ajuste de histórico como o processo de atualizar um modelo de reservatório de modo que a simulação numérica da produção esteja consistente com os dados de produção medidos [19]. Assim, este processo compreende a assimilação, ou incorporação, de dados dinâmicos ao modelo de forma a aprimorar a caracterização do reservatório.

Portanto, é altamente desejável a adoção de estratégias eficientes de ajuste de histórico, empregando uma abordagem assistida por métodos que permitam a incorporação de dados ao modelo de forma ágil, com o objetivo de suportar uma melhor quantificação de incertezas e, por fim, proporcionar uma maior previsibilidade nas atividades das empresas de E&P.

1.1

Definição do Problema

Métodos de ajuste assistido de histórico tem sido amplamente discutidos na literatura [19, 37, 18, 55, 5, 32, 31, 40], entretanto, vem ganhando destaque em tempos recentes um conjunto de métodos cuja formulação é baseada no filtro de Kalman [20], técnica que foi originalmente desenvolvida para aplicações na área de controle, navegação e processamento de sinais, mas foi estendida para a assimilação de dados a modelos de reservatórios a partir do início dos anos 2000 [13].

Dentre estes métodos, pode ser destacado o *ensemble smoother with multiple data assimilation* (ES-MDA), proposto por Emerick e Reynolds [11], que vem demonstrando excelentes resultados em termos da qualidade do ajuste e da quantificação de incertezas, além de se sobressair por sua eficiência e simplicidade de implementação computacional, sendo capaz de tratar problemas com uma quantidade muito grande de parâmetros a um custo computacional relativamente baixo [2, 3, 46], estando sua implementação disponível em algumas plataformas comerciais para ajuste de histórico.

Entretanto, o método ES-MDA foi desenvolvido apoiando-se em hipóteses lineares e gaussianas que podem impactar o desempenho do processo de ajuste a medida que estas sejam violadas [3]. O caráter iterativo do método tende a minimizar os efeitos relacionados a não linearidade do problema, porém o ajuste de parâmetros que se caracterizam por distribuições de probabilidade que se afastem da gaussiana representa um desafio ao método. Assim, apesar dos bons resultados no ajuste de histórico ao considerar propriedades contínuas como variáveis do problema, como a porosidade e a permeabilidade, sua utilização pode ser até mesmo inviabilizada quando é necessário ajustar propriedades que possuem valores categóricos, como por exemplo ao realizar o ajuste do modelo de fácies geológicas, inerentemente um parâmetro categórico que representa classes de rocha, agrupadas de forma a refletir sua origem, mineralogia e sedimentação, entre outras características.

Ainda assim, na literatura são reportadas algumas estratégias que se propõe a tratar propriedades categóricas utilizando métodos baseados no filtro de Kalman [61, 44]. Porém, é muito comum quando há a necessidade de considerar este tipo de atributo limitar-se a avaliar um número restrito de cenários estáticos, recorrendo-se à métodos estocásticos - como algoritmos genéticos [55, 5, 32] - para selecionar aquele que melhor representa os dados, ou até mesmo recorrer à realização de um ajuste manual do modelo [54].

Uma abordagem recente para tratar desse problema tem sido incorporar redes de aprendizado profundo (*deep learning*) ao processo de ajuste de histórico. Nestes trabalhos [2, 3, 34], diversas arquiteturas de rede tem sido propostas para melhor tratar aspectos específicos do problema. Entretanto, há a oportunidade de se explorar arquiteturas de rede de aprendizado profundo utilizadas para executar tarefas de tradução imagem-imagem (I2I) - que consiste da transformação de uma imagem de um domínio de origem para um domínio de destino mantendo seu conteúdo semântico - integrando-as ao

processo de ajuste de histórico. Essa é uma área em ampla evolução, cujos resultados impressionam pela consistência e qualidade das imagens traduzidas, sendo interessante se aproveitar da analogia existente entre a representação matricial de uma imagem e a estrutura em malha (*grid*) das propriedades de um modelo de reservatório de forma a se beneficiar do alto desempenho dessas redes, utilizando-as no contexto de ajuste de parâmetros categóricos do modelo de reservatórios.

Portanto, o presente trabalho tem por objetivo investigar o estado da arte das técnicas de tradução imagem-imagem, em especial àquelas baseadas em redes generativas, de forma a viabilizar a adaptação e o treinamento deste tipo de arquitetura com a finalidade de gerar, a partir de uma malha de propriedades contínuas de entrada (porosidade, permeabilidade etc), a propriedade categórica correlata (como as fácies geológicas, por exemplo), num processo análogo ao de segmentação semântica de imagens¹. Ao final da etapa de treinamento, pretende-se realizar o acoplamento do módulo gerador da rede I2I ao método ES-MDA, permitindo assim a reconstrução da propriedade categórica após a atualização das propriedades contínuas, a cada iteração para assimilação dos dados históricos de produção.

1.2

Resumo dos Capítulos

Para alcançar o objetivo proposto, os assuntos abordados nesta dissertação estão organizados da seguinte forma:

- uma breve discussão sobre metodologias de ajuste assistido de histórico, com foco nos métodos baseados em filtro de Kalman, em especial o *ensemble smoother with multiple data assimilation* (ES-MDA) (Capítulo 2);
- apresentação dos fundamentos teóricos relacionados à área de tradução imagem-imagem (I2I) e sua recente evolução através da utilização de arquiteturas de redes generativas profundas, além de selecionar a arquitetura utilizada na continuidade do estudo (Capítulo 3);
- descrição da metodologia proposta para assimilação de dados a modelos de reservatórios, utilizando o ES-MDA integrado a redes de tradução imagem-imagem, abordando a analogia existente entre a representação

¹A segmentação semântica de imagens tem como objetivo a detecção de formas e/ou objetos em uma imagem, através da rotulação ao nível *pixel* da classe correspondente ao atributo alvo naquela região da imagem [26].

de imagens e propriedades do modelo, além de comparar com outras estratégias de ajuste assistido de histórico envolvendo redes de aprendizado profundo (Capítulo 4);

- demonstração das etapas para avaliação da eficácia da metodologia, descrevendo a composição dos casos de estudo (definição do modelo de reservatórios e geração das realizações geológicas), definição de métricas para análise dos resultados, descrição e treinamento da rede I2I e, por fim, a realização do processo de assimilação de dados ao modelo e a discussão dos respectivos resultados (Capítulo 5); e
- síntese das conclusões e contribuições do trabalho, além de recomendações para futuras pesquisas (Capítulo 6).

2

Ajuste de Histórico de Modelos de Reservatórios

A modelagem de um reservatório de petróleo tem o propósito de subsidiar os estudos necessários para a adequada previsão do comportamento de produção de uma jazida, auxiliando na definição de um plano de drenagem que permita maximizar a sua recuperação. Neste processo, é necessário que engenheiros e geocientistas realizem a caracterização dos parâmetros estáticos (porosidade, permeabilidade etc) e dinâmicos (fluido, interação rocha-fluido etc) do reservatório, representando-os através de um modelo numérico, no qual o reservatório é dividido em um conjunto de células onde serão aplicadas equações fundamentais de escoamento em meios porosos, permitindo assim a simulação da produção do reservatório.

Neste contexto, o processo de predição da resposta de um sistema físico cujos parâmetros estão completamente caracterizados - como a estimativa de produção a partir de um modelo de reservatórios - pode ser definido como um problema direto [52]. Entretanto, para a modelagem de uma jazida há poucos dados disponíveis provenientes de observação direta do reservatório, constituídos em geral por dados estáticos esparsos coletados em poços perfurados, através amostras de rocha, testemunhos¹ e perfis². Além deles, também são coletados um conjunto de dados dinâmicos que em sua maioria são obtidos de maneira indireta e sujeitos a diversos erros de medição, como os dados de produção dos poços (vazões, pressões etc), que são monitorados ao longo da produção da jazida. Assim, é importante utilizar a informação contida nestes dados dinâmicos observados para caracterizar os parâmetros do modelo.

Este processo de incorporação de dados observados ao modelo de reservatórios, denominado ajuste de histórico, pode ser classificado como um problema inverso uma vez que seu objetivo é o de determinar propriedades fisicamente plausíveis de um sistema (reservatório), ou obter informações sobre estas propriedades, dadas as respostas observadas do sistema (dados históricos de produção) a determinados estímulos (condições operacionais) [37].

Assim, para se obter o conjunto de parâmetros do modelo (\mathbf{m}) cuja resposta simulada (\mathbf{d}) melhor represente os dados históricos observados (\mathbf{d}_{hist}),

¹Amostra cilíndrica longitudinal do trecho de um poço perfurado.

²Medição das propriedades físicas das rochas ao longo de um poço.

pode-se representar o processo de ajuste de histórico como um problema de otimização, uma vez que se deseja minimizar a diferença entre o dado simulado do modelo e os dados observados. Desse modo, inicialmente pode-se descrever a função objetivo (\mathcal{O}) a ser minimizada pela seguinte equação:

$$\mathcal{O} = (\mathbf{d}_{hist} - \mathbf{d})^T \mathbf{C}_D^{-1} (\mathbf{d}_{hist} - \mathbf{d}), \quad (2-1)$$

onde \mathbf{C}_D é a matriz covariância do ruído nos dados medidos, a qual define o nível de confiança dos dados e, portanto, o peso relativo que cada dado terá no ajuste [46].

Adicionalmente, a resposta simulada do modelo pode ser considerada como o resultado de uma transformação $\mathbf{g}(\cdot)$ aplicada sobre os parâmetros do modelo de simulação. Assim, pode-se considerar que:

$$\mathbf{d} = \mathbf{g}(\mathbf{m}); \quad e \quad (2-2)$$

$$\mathcal{O}(\mathbf{m}) = (\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m}))^T \mathbf{C}_D^{-1} (\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m})). \quad (2-3)$$

Ainda assim, é desejável que os parâmetros do modelo (\mathbf{m}) respeitem uma representação geológica conceitual pré-definida pelos geocientistas. Para manter esta consistência, pode-se incluir um termo de regularização à função objetivo para que esta seja penalizada à medida que os parâmetros do modelo \mathbf{m} se afastem dos parâmetros do modelo geológico inicial, ou modelo *a priori* (\mathbf{m}_{prior}), ao longo do processo de ajuste de histórico:

$$\begin{aligned} \mathcal{O}(\mathbf{m}) = & (\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m}))^T \mathbf{C}_D^{-1} (\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m})) \\ & + (\mathbf{m} - \mathbf{m}_{prior})^T \mathbf{C}_M^{-1} (\mathbf{m} - \mathbf{m}_{prior}) \end{aligned} \quad (2-4)$$

onde \mathbf{C}_M é a matriz covariância dos parâmetros do modelo.

Portanto, os métodos de ajuste assistido de histórico tradicionais buscam definir os parâmetros do modelo \mathbf{m} que minimizem a função $\mathcal{O}(\mathbf{m})$, ou seja:

$$\mathbf{m}_{post} = \arg \min_{\mathbf{m}} \{ \mathcal{O}(\mathbf{m}) \}, \quad (2-5)$$

definindo-se por \mathbf{m}_{post} o conjunto de parâmetros do modelo ajustado aos dados observados (ou modelo *a posteriori*).

2.1

Métodos de Ajuste Assistido de Histórico

Existe uma grande variedade de métodos que se propõe a resolver o problema de ajuste de histórico de forma assistida, sendo que as estratégias

utilizadas para solucionar este problema de otimização podem ou não ser baseadas no cálculo do gradiente da função objetivo.

Os métodos baseados em gradiente utilizam as derivadas da função objetivo $\mathcal{O}(\mathbf{m})$ para determinar as atualizações a serem realizadas nos parâmetros do modelo [35]. Uma estratégia simplificada seria utilizar o método de Newton [37] para atualizar iterativamente o modelo, conforme a seguinte equação:

$$\mathbf{m}^\ell = \mathbf{m}^{\ell-1} - \mathbf{H}_{\ell-1}^{-1} \nabla \mathcal{O}(\mathbf{m}^{\ell-1}) \quad , \quad (2-6)$$

onde ℓ é uma das iterações, $\nabla \mathcal{O}$ é o vetor das derivadas parciais de primeira ordem da função objetivo $\mathcal{O}(\mathbf{m})$ e \mathbf{H} é a matriz das derivadas parciais de segunda ordem de $\mathcal{O}(\mathbf{m})$ (denominada Hessiana). Assim, na primeira iteração ($\ell = 1$) teríamos $\mathbf{m}^0 = \mathbf{m}_{prior}$ e, ao se atingir um critério de parada predefinido, teríamos o modelo ajustado $\mathbf{m}_{post} = \mathbf{m}^\ell$.

Há algumas implementações baseadas em gradiente descritas na literatura, como os métodos *Adjoint* [37, 18] e *Forward* [41]. Contudo, estes métodos são pouco utilizados em aplicações práticas de ajuste de histórico de modelos de reservatórios, uma vez que, em geral, o cálculo das derivadas pode demandar um alto custo computacional, além de necessitar ser implementado intrinsecamente ao código do simulador de reservatórios.

Por outro lado, métodos estocásticos tem sido amplamente utilizados na indústria, dentre os quais podem ser citados os métodos baseados em algoritmos evolucionários (algoritmos genéticos) [55, 5, 32] e o método *Particle Swarm Optimization* (PSO) [21, 31, 40], devido à sua capacidade de encontrar múltiplas soluções para o problema de otimização, além de serem facilmente integráveis aos simuladores de reservatório comerciais.

Entretanto, as principais desvantagens dos métodos estocásticos são a sua lenta convergência, devido à complexidade do problema e ao caráter exploratório do método, o que leva à necessidade de uma severa redução dos parâmetros incertos (ajustáveis) a serem considerados, reduzindo significativamente o espaço de busca por soluções para ajuste de histórico [19]. Estes métodos, em geral, buscam minimizar apenas o termo da função objetivo $\mathcal{O}(\mathbf{m})$ referente à diferença entre a resposta simulada e os dados históricos observados, representado pela equação 2-3.

Outra alternativa são os métodos recursivos, assim denominados pois

as modificações a cada passo de atualização das propriedades do modelo são estimadas em função do resultado da atualização do passo anterior [37]. Dentre eles, uma abordagem computacionalmente eficiente e de implementação relativamente simples são os métodos baseados em filtro de Kalman, que têm ganhado evidência na área de ajuste de histórico pela sua robustez e capacidade de trabalhar com um grande número de parâmetros ajustáveis.

2.2 Métodos Baseados em Filtro de Kalman

O filtro de Kalman tem uma longa tradição de utilização nas áreas de sistemas de controle, navegação e processamento de sinais, sendo uma técnica que se propõe a assimilar dados sequencialmente, de forma a se obter uma estimativa atualizada dos parâmetros ou estados de um modelo, através da correção de uma estimativa anteriormente obtida, podendo portanto ser classificado como um estimador recursivo [1]. Apesar desta técnica ter sido originalmente desenvolvida para tratar apenas de sistemas lineares, diversos métodos tem sido propostos para adaptar sua utilização a sistemas dinâmicos não lineares.

De forma concisa, o processo de atualização pelo filtro de Kalman dos parâmetros do modelo, que se propaga de uma iteração $\ell - 1$ para a próxima, pode ser descrito pela seguinte equação:

$$\mathbf{m}^\ell = \mathbf{m}^{\ell-1} + \mathbf{K}^\ell [\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m}^{\ell-1})], \quad (2-7)$$

onde \mathbf{K}^ℓ é denominado “ganho de Kalman”.

Dentre as abordagens que se demonstraram aplicáveis à área de ajuste de histórico de reservatórios, o primeiro foi o método *ensemble Kalman filter* (EnKF) que é uma implementação de Monte Carlo, que fornece uma alternativa para o filtro de Kalman tradicional a ser utilizada para tratar sistemas dinâmicos não lineares, onde um conjunto de realizações (modelos) são utilizados para estimar a média e a matriz covariância dos parâmetros do modelo, que serão utilizados para estimar o ganho de Kalman [37].

Entretanto, a assimilação sequencial dos dados representa um problema para aplicações práticas, pois a cada passo de assimilação de dados é necessário parar e posteriormente continuar a simulação de reservatórios. Assim, o tempo total do processo de ajuste é penalizado, devido à necessidade de se lidar com a reinicialização das simulações, sendo ainda mais crítico caso sejam adotadas

soluções de simulação distribuída para paralelizar a execução.

Uma alternativa desenvolvida para mitigar as desvantagens da assimilação sequencial foi o método *ensemble smoother* (ES) [48], que apresenta uma formulação similar ao EnKF, mas com todos os dados sendo assimilados simultaneamente. Entretanto, os resultados obtidos pelo método ES também não tem demonstrado um desempenho satisfatório em aplicações reais de ajuste de histórico.

Para melhorar a qualidade e a eficiência do ajuste de histórico obtido pelo ES, foi então proposto o método *ensemble smoother with multiple data assimilation* (ES-MDA) [11], podendo este ser considerado como um ES iterativo, no qual o número de iterações é predefinido. Dentre os métodos baseados em filtro de Kalman, o ES-MDA é o que tem demonstrado os melhores resultados em tarefas de incorporação de dados a modelos de reservatório, tanto na literatura quanto em aplicações reais na indústria de E&P.

2.2.1

Ensemble Smoother with Multiple Data Assimilation (ES-MDA)

A abordagem adotada no método ES-MDA para reduzir os efeitos da não linearidade do problema de ajuste de histórico é a realização do processo de assimilação de um mesmo conjunto de dados históricos (\mathbf{d}_{hist}) múltiplas vezes, como um método iterativo, uma vez que a execução de um único passo de assimilação poderia significar uma correção excessiva dos parâmetros do modelo, reduzindo a eficiência do processo de incorporação dos dados.

Em sua definição, o método está fundamentado no princípio de que, para casos lineares e gaussianos, a assimilação dos mesmos dados múltiplas vezes com uma matriz de covariância do ruído dos dados medidos \mathbf{C}_D inflada (multiplicada por um fator $\alpha > 1$) é equivalente a assimilar o dado uma única vez com a matriz de covariância original, desde que o coeficiente de inflação α satisfaça a seguinte condição:

$$\sum_{\ell=1}^{N_a} \frac{1}{\alpha_\ell} = 1, \quad (2-8)$$

onde N_a é o número de ciclos de assimilação de dados (iteraões) realizados pelo do método e ℓ a respectiva iteração.

Esta estratégia visa assegurar que a divisão do processo de assimilação de dados em passos menores seja realizada de forma estatisticamente consistente

[12], o que reduz a magnitude da correção linear aplicada aos modelos a cada iteração, através da utilização da matriz de covariância do ruído nos dados medidos inflada ($\alpha \mathbf{C}_D$).

Assim, o processo de assimilação de dados pelo método ES-MDA, durante uma iteração ℓ , de uma realização \mathbf{m}_j - contida em um conjunto de N_m modelos, cada qual composto por N_p parâmetros - pode ser descrito da seguinte forma:

$$\mathbf{m}_j^\ell = \mathbf{m}_j^{\ell-1} + \mathbf{C}_{MS}^\ell (\mathbf{C}_S^\ell + \alpha_\ell \mathbf{C}_D)^{-1} (\mathbf{d}_{hist} + \boldsymbol{\varepsilon}_j^\ell - \mathbf{g}(\mathbf{m}_j^{\ell-1})), \quad (2-9)$$

podendo ser reescrito como:

$$\mathbf{m}_j^\ell = \mathbf{m}_j^{\ell-1} + \mathbf{K}^\ell (\mathbf{d}_{hist} + \boldsymbol{\varepsilon}_j^\ell - \mathbf{g}(\mathbf{m}_j^{\ell-1})), \quad \text{sendo} \quad (2-10)$$

$$\mathbf{K}^\ell = \mathbf{C}_{MS}^\ell (\mathbf{C}_S^\ell + \alpha_\ell \mathbf{C}_D)^{-1}, \quad (2-11)$$

onde \mathbf{C}_S é a matriz de covariância dos dados simulados, \mathbf{C}_{MS} é a matriz de covariância cruzada entre os parâmetros do modelo e os dados simulados, $\boldsymbol{\varepsilon}$ é um ruído aleatório com uma distribuição de probabilidade $\mathcal{N}(0, \alpha_\ell \mathbf{C}_D)$ e $j = 1, 2, \dots, N_m$.

Assim, a cada iteração ℓ para assimilação de dados, as matrizes \mathbf{C}_S^ℓ e \mathbf{C}_{MS}^ℓ são estimadas considerando o resultado das simulações de todo o conjunto de modelos $\{\mathbf{m}_j^{\ell-1}\}_{j=1}^{N_m}$, atualizados na iteração anterior ($\ell - 1$).

Portanto, a partir de um conjunto de realizações *a priori* $\{\mathbf{m}_{prior,j}\}_{j=1}^{N_m}$ construído de forma a representar as incertezas presentes no modelo geológico conceitual do reservatório, é possível aplicar o método para o ajuste assistido de histórico dos modelos. Ao final dos N_a ciclos de assimilação de dados é esperado que a resposta simulada dos modelos esteja mais aderente aos dados históricos de produção, permitindo uma melhor caracterização da incerteza dos parâmetros do modelo.

Para maiores detalhes sobre a formulação do método, a descrição do algoritmo para a aplicação do ES-MDA e a construção das matrizes de covariância serão demonstradas no apêndice A.

2.2.2

Localização da Covariância

Conforme descrito, o método ES-MDA depende de um conjunto de modelos para estimar as matrizes de covariância e, por consequência, é beneficiado quanto maior for o número de amostras iniciais deste conjunto. Entretanto, nas aplicações práticas de ajuste de histórico, há um conjunto relativamente pequeno de modelos ($N_m \leq 200$), uma vez que o crescimento do número de amostras representa um aumento no número de simulações de reservatórios a serem realizadas, cujo custo computacional é alto. Assim, o desempenho do método pode ser prejudicado por correlações espúrias entre os dados medidos e os parâmetros do modelo ou pela redução excessiva das incertezas ao final do processo [46].

A técnica de localização da covariância [10] se propõe a reduzir esses efeitos, fazendo com que a influência de um dado no ajuste dos parâmetros de um dos blocos da malha de simulação seja reduzida quanto maior for a distância deste bloco à posição em que este dado tenha sido medido.

A aplicação da técnica [9] é realizada através da regularização do ganho de Kalman \mathbf{K}^ℓ por uma matriz de localização da covariância \mathbf{R}_{MD} , cujos elementos são calculados, em geral, pela função de Gaspari-Cohn, com base no tamanho das regiões de influência de cada poço. Essa regularização é realizada através da aplicação do produto elemento a elemento das duas matrizes (produto Schur), ou seja:

$$\mathbf{R}_{\text{MD}} \circ \mathbf{K}^\ell, \quad (2-12)$$

sendo possível portanto reescrever a equação 2-10, incorporando a técnica de localização ao processo ES-MDA:

$$\mathbf{m}_j^\ell = \mathbf{m}_j^{\ell-1} + (\mathbf{R}_{\text{MD}} \circ \mathbf{K}^\ell)(\mathbf{d}_{\text{hist}} + \boldsymbol{\varepsilon}_j^\ell - \mathbf{g}(\mathbf{m}_j^{\ell-1})). \quad (2-13)$$

Portanto, a metodologia descrita nesta dissertação irá considerar a aplicação do método ES-MDA em conjunto à técnica de localização da covariância, cujo detalhamento para construção da matriz \mathbf{R}_{MD} é descrito no apêndice B.

3

Tradução Imagem-imagem

O problema de tradução imagem-imagem (I2I) pode ser definido como o processo de transformação de uma imagem de um domínio de origem para um domínio de destino, mantendo o conteúdo semântico intrínseco de suas representações. Assim, considerando que uma imagem pode ser descrita por uma matriz de *pixels* \mathbf{X} , seja $\mathbf{X}_A \in S_A$ uma imagem no espaço de origem e $\mathbf{X}_B \in S_B$ a representação da imagem no espaço de destino, o problema pode ser modelado como a tarefa de definir uma transformação $\mathbf{G}(\cdot)$ que reproduza uma aproximação \mathbf{X}'_B da imagem \mathbf{X}_B , tal que [38]:

$$\mathbf{X}'_B \in S_B : \mathbf{X}'_B = \mathbf{G}(\mathbf{X}_A) \quad (3-1)$$

Para que essa transformação seja eficiente, é necessário que a informação contida na imagem seja tratada em seus diversos graus de abstração. Assim, o conteúdo de uma imagem pode ser classificado pelos seguintes níveis complexidade [8]:

- Nível 0 - Dados brutos: valores numéricos individuais de cada *pixel*;
- Nível 1 - Atributos Primitivos: refere-se a características como cores (histogramas), texturas, formas ou a localização espacial dos elementos da imagem;
- Nível 2 - Atributos Lógicos: permitem caracterizar objetos de interesse na imagem, identificando padrões e formas complexas; e
- Nível 3 - Atributos Abstratos (ou Semânticos): envolve um grau mais alto de abstração ao atribuir uma concepção ou um significado à elementos da imagem, envolvendo o aprendizado das correlações entre os diversos atributos e padrões.

As técnicas para processamento de informações de imagens vem evoluindo desde a década de 1960 envolvendo inicialmente formas de representação da informação visual [28], a definição dos fundamentos para reconhecimento de objetos [29, 27] e a segmentação de formas complexas [45]. Entretanto, tais abordagens essencialmente são capazes de tratar apenas os atributos primitivos e lógicos, sendo ainda limitados na extração de significados ou conceitos mais abstratos da imagem, problema este conhecido como lacuna semântica (*semantic gap*).

Diversas estratégias foram propostas para minimizar o problema da lacuna semântica [16], no entanto, avanços recentes na tarefa de reconhecimento de imagem foram obtidas com a introdução de técnicas de aprendizado de profundo (*deep learning*), envolvendo a utilização de redes convolucionais.

Redes neurais convolucionais (CNN) são um tipo de rede neural especializado no processamento de dados estruturados numa topologia de malha [14], como as matrizes que representam uma imagem. Estas redes (figura 3.1) possuem pelo menos uma camada que realiza um tipo particular de operação linear denominado convolução, cujos neurônios estão dispostos de tal forma a processar porções da matriz de entrada, denominados campos receptores, dos quais podem ser extraídos atributos visuais elementares, como por exemplo arestas e bordas, que serão combinadas por camadas posteriores considerando funções de ativação específicas [25].

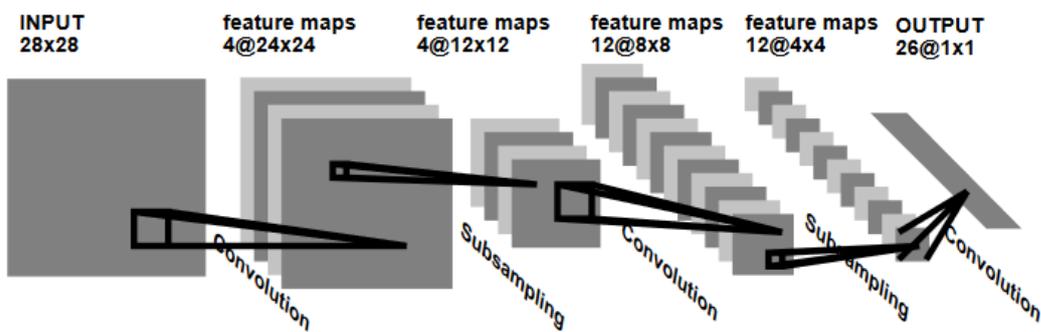


Figura 3.1: Rede neural convolucional [25]

No contexto de tradução I2I, estas redes proporcionaram um grande avanço para a solução de tarefas que dependem de uma compreensão semântica da imagem, como segmentação [26], mudança de estilo [60] e predição de imagens baseada em contexto [39]. Com a contínua evolução destas redes, atualmente se destacam as redes baseadas em modelos convolucionais profundos, como as arquiteturas *Encoder-decoder* e as *Generative Adversarial Networks* (GAN).

3.1

Arquiteturas *Encoder-decoder*

A problema de tradução na perspectiva de aprendizado de máquina pode ser descrito como a tarefa de aprender a distribuição condicional $p(\mathbf{r}|\mathbf{x})$ de uma representação \mathbf{r} dada uma entrada \mathbf{x} [6]. Neste contexto, pode-se definir

uma rede *encoder-decoder* como uma rede neural treinada para sintetizar em sua saída uma representação do atributo de entrada em um domínio distinto do original, possuindo internamente uma camada oculta que representa um espaço latente onde a entrada é codificada com uma dimensionalidade reduzida. Assim, este tipo de rede pode ser decomposto em dois componentes (figura 3.2):

- uma função *encoder* $f(\cdot)$, tal que $\mathbf{h} = f(\mathbf{x})$; e
- uma função *decoder* $g(\cdot)$, que produz a reconstrução $\mathbf{r} = g(\mathbf{h})$,

sendo \mathbf{x} o atributo de entrada, \mathbf{h} a representação codificada e \mathbf{r} a representação da entrada em outro domínio.

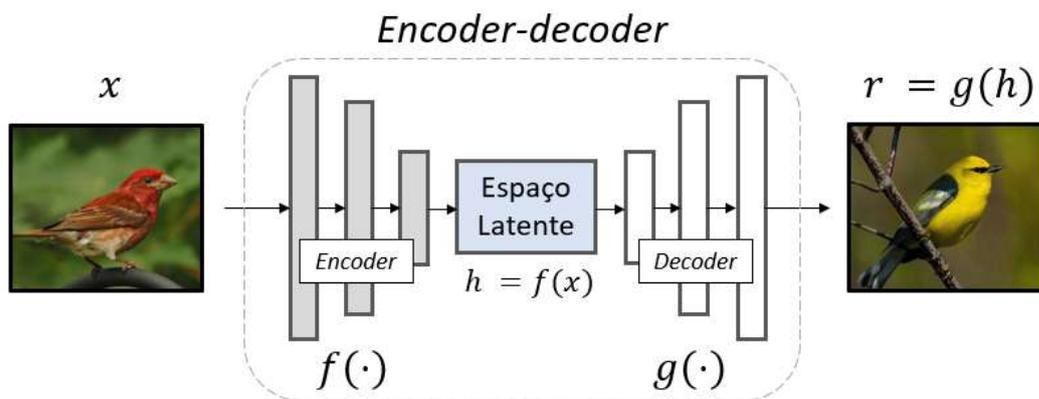


Figura 3.2: Diagrama de uma rede *encoder-decoder*.

Uma adaptação da arquitetura *encoder-decoder* são as redes U-Net, que ganharam popularidade em trabalhos de segmentação semântica de imagens biomédicas [42]. Em sua estrutura são incluídas conexões residuais entre os blocos da rede, como mostrado na figura 3.3. Essas conexões fornecem informações adicionais às camadas finais da rede que ajudam o *decoder* a gerar melhores recursos semânticos. Eles também atuam durante o treinamento como uma conexão de atalho que ajuda no fluxo de gradientes para as camadas iniciais, sem qualquer degradação.

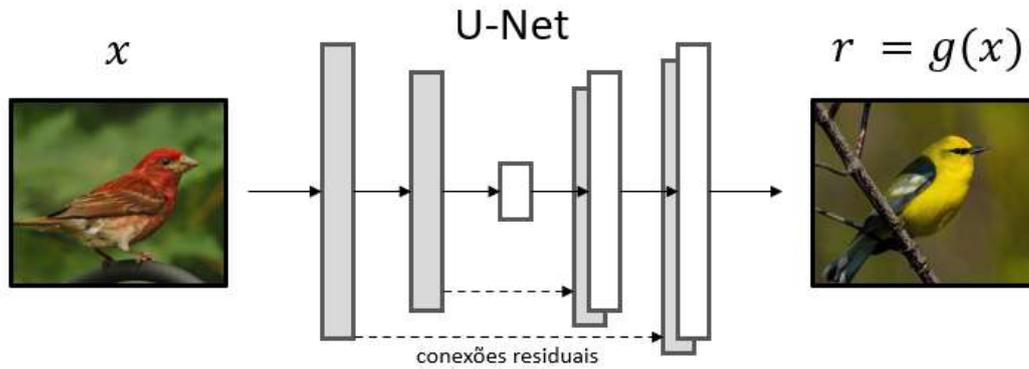


Figura 3.3: Diagrama da rede U-Net

Existem diversas redes que adaptam a estrutura *encoder-decoder* para executar tarefas de tradução I2I, sendo uma arquitetura presente nos módulos geradores de algumas GANs.

3.2 Arquiteturas Generativas Adversárias

A estrutura fundamental das redes generativas adversárias, ou GANs [15], consiste do acoplamento de dois modelos que competem entre si:

- um modelo gerador $G(\cdot)$, cujo objetivo é produzir amostras plausíveis dos dados de uma base de treinamento; e
- um modelo discriminador $D(\cdot)$, que deve ser capaz de fazer a distinção entre as amostras produzidas pela rede geradora $G(\cdot)$ e as amostras oriundas da base de treinamento.

Assim, o processo de treinamento destas redes é um jogo de soma-zero entre as redes geradora e discriminadora. Portanto, considerando-se:

- \mathbf{x} uma amostra verdadeira, pertencente a uma base de treinamento;
- θ_G e θ_D os hiper-parâmetros das redes geradora e discriminadora, respectivamente; e
- \mathbf{z} um vetor aleatório amostrado a partir da distribuição de probabilidade *a priori* do modelo $p(\mathbf{z})$, que fará com que a rede geradora produza uma amostra falsa $\mathbf{x}' = G(\mathbf{z}; \theta_G)$;

então, pretende-se que a rede discriminadora indique a probabilidade de que uma amostra seja verdadeira, de modo que $D(\mathbf{x}; \theta_D) \rightarrow 1$, ou seja falsa,

fazendo com que $D(G(\mathbf{z}); \theta_D) \rightarrow 0$.

Desse modo, o treinamento da GAN pressupõe que o discriminador aprenda a classificar as amostras como verdadeiras ou falsas e, concorrentemente, o gerador tente confundi-lo, fazendo-o classificar as amostras geradas como reais. Ao final do treinamento, as amostras produzidas pelo gerador devem ser indistinguíveis das amostras verdadeiras, com $D(G(\mathbf{z}); \theta_D) \rightarrow 1/2$, podendo-se descartar a rede discriminadora. Para isso, a função objetivo do processo de otimização conjunto pode ser descrita como:

$$\min_{\theta_G} \max_{\theta_D} V(D_{\theta_D}, G_{\theta_G}) = \mathbb{E}_{\mathbf{x} \sim p_{\mathbf{x}}(\mathbf{x})} [\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_{\mathbf{z}}(\mathbf{z})} [\log(1 - D(G(\mathbf{z})))] \quad (3-2)$$

Adicionalmente, é possível estender este modelo, fazendo com que tanto o gerador quanto o discriminador sejam condicionados por alguma informação extra, sendo aqui definido pelo vetor \mathbf{y} , de forma que a rede geradora produza uma amostra falsa $\mathbf{x}' = G(\mathbf{z}|\mathbf{y}; \theta_G)$. Assim, surgiram as *Conditional Adversarial Networks*, ou CGANs [30]. Neste contexto, a função objetivo de treinamento pode ser adaptada, fazendo com que a amostra verdadeira também esteja condicionada à informação extra no discriminador ($D(\mathbf{x}|\mathbf{y})$), logo:

$$\min_{\theta_G} \max_{\theta_D} V(D_{\theta_D}, G_{\theta_G}) = \mathbb{E}_{\mathbf{x} \sim p_{\mathbf{x}}(\mathbf{x})} [\log D(\mathbf{x}|\mathbf{y})] + \mathbb{E}_{\mathbf{z} \sim p_{\mathbf{z}}(\mathbf{z})} [\log(1 - D(G(\mathbf{z}|\mathbf{y})))] \quad (3-3)$$

A figura 3.4 apresenta a estrutura geral de uma CGAN que poderia ser utilizada no contexto de tradução imagem-imagem. Assim, o objetivo é que o módulo discriminador aprenda a classificar se uma imagem sintetizada pelo gerador possui ou não as características determinadas pela base de treinamento, enquanto o módulo gerador aprende a enganar o discriminador. Ambos os módulos são condicionados pela imagem de entrada.

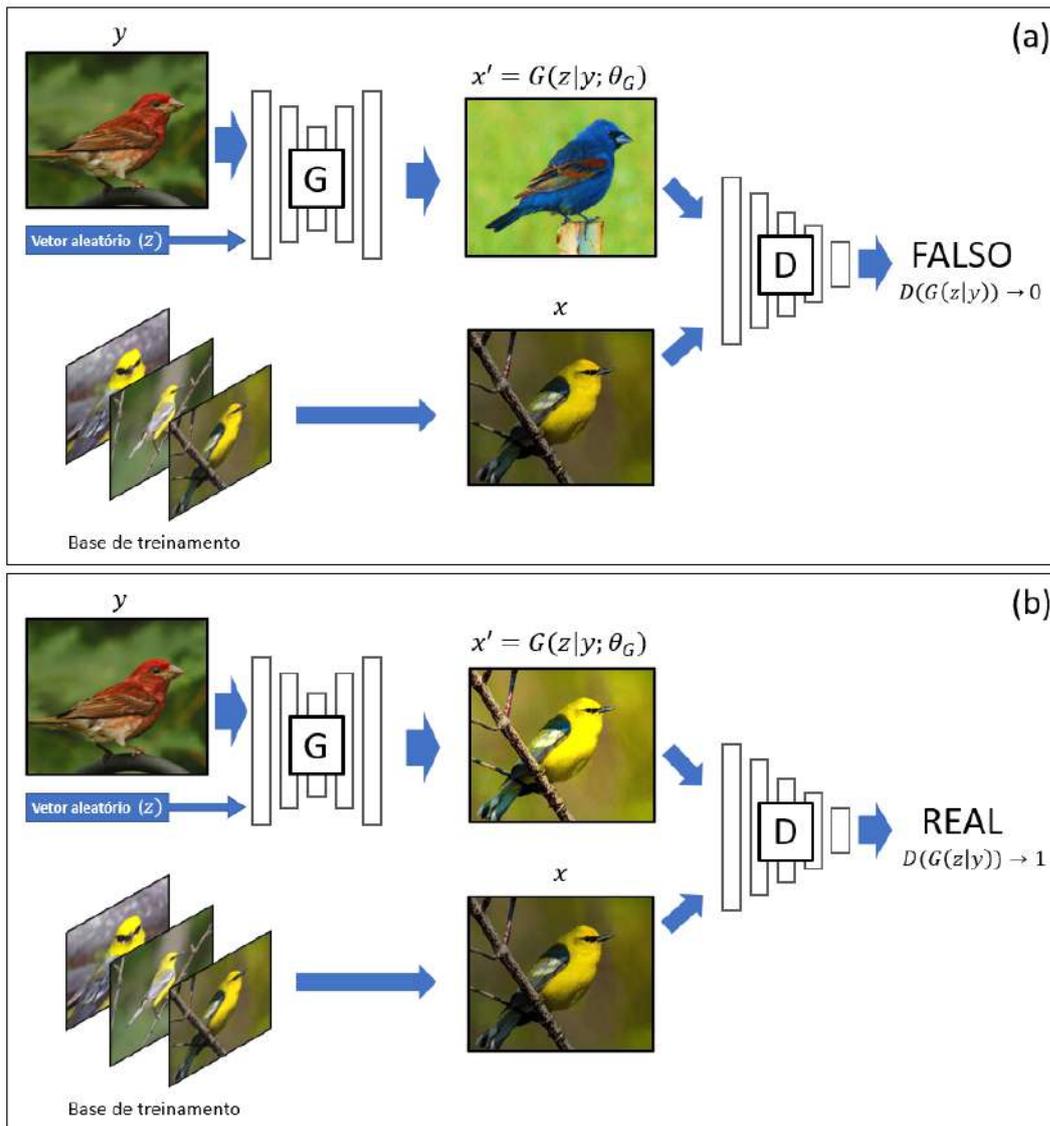


Figura 3.4: Estrutura geral de uma CGAN: módulo discriminador aprende a classificar se uma imagem sintetizada pelo gerador é real (b) ou falsa (a), enquanto o gerador tenta enganar o discriminador.

3.3

Redes Generativas para Tradução Imagem-imagem

O desenvolvimento de modelos generativos profundos representou uma mudança de paradigma para a área de tradução imagem-imagem. Uma vez que este processo tem o objetivo de produzir em sua saída uma imagem que represente o mesmo contexto semântico associado à imagem de entrada, é desejável que o modelo a ser utilizado possua um método de aprendizado que a direcione para este objetivo. Coincidentemente, o processo de aprendizado implementado para as GANs possui essas características, fazendo com que estas redes, em especial a sua variante condicional (CGAN), sejam muito eficientes

para tratar de problemas I2I, uma vez que a rede aprende a correlacionar a distribuição do domínio de destino com a distribuição do domínio de origem, tornando a imagem gerada indistinguível de uma imagem verdadeira.

Conseqüentemente, diversas arquiteturas que incorporam modelos generativos tem sido propostas de forma a atender a características particulares das tarefas de I2I. Uma primeira distinção pode ser feita para diferenciar problemas cujo treinamento será realizado considerando dados pareados ou não-pareados. Um conjunto de treinamento com N dados pareados é aquele onde há uma correspondência direta entre uma imagem de entrada \mathbf{x}_i e uma imagem alvo \mathbf{y}_i , podendo ser representado por $\{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^N$. Em contrapartida, ao considerar dados não-pareados teremos conjuntos independentes de imagens de entrada $\{\mathbf{x}_i\}_{i=1}^N$ e imagens alvo $\{\mathbf{y}_i\}_{i=1}^N$, não havendo associação de elementos individuais entre ambos os grupos [62].

Portanto, considerando os conceitos tradicionais da área de aprendizado de máquina, é possível classificar essas redes em função da estratégia de aprendizado adotada [43], sendo estas:

- **Aprendizado supervisionado:** utiliza um conjunto de dados pareados de imagens para o treinamento da rede, sendo o método mais comum para problemas de classificação de imagens utilizando redes neurais profundas;
- **Aprendizado não-supervisionado:** utiliza conjuntos não-pareados de imagens, sendo muito aplicado para tarefas I2I, uma vez que pode ser difícil coletar uma grande base de imagens pareadas; e
- **Aprendizado semi-supervisionado:** para alguns problemas específicos, se dispõe de um um amplo número de imagens não pareadas conjuntamente a uma base de dados pareados limitada, que também é utilizada durante o treinamento para aumentar o desempenho do processo de tradução.

Outro aspecto importante a ser avaliado é a relação entre a topologia dos modelos e o espaço de soluções do problema. Em muitos casos, o objetivo é apenas a tradução da imagem de um domínio para outro, como em tarefas de colorização, aumento de resolução da imagem e segmentação semântica (figura 3.5). Uma extensão deste objetivo seria ainda traduzir de um domínio para outro, mas modelando-se uma distribuição de potenciais imagens no domínio de destino, numa abordagem multimodal, tendo como resultado imagens diversas, sendo cada uma delas uma representação possível da imagem

original, como por exemplo obter múltiplas representações de um objeto a partir de um esboço (figura 3.6). Uma terceira vertente seria o modelo ter a capacidade de aprender a traduzir imagens entre múltiplos domínios, tal como representar a imagem de uma paisagem em diversas estações do ano (figura 3.7).

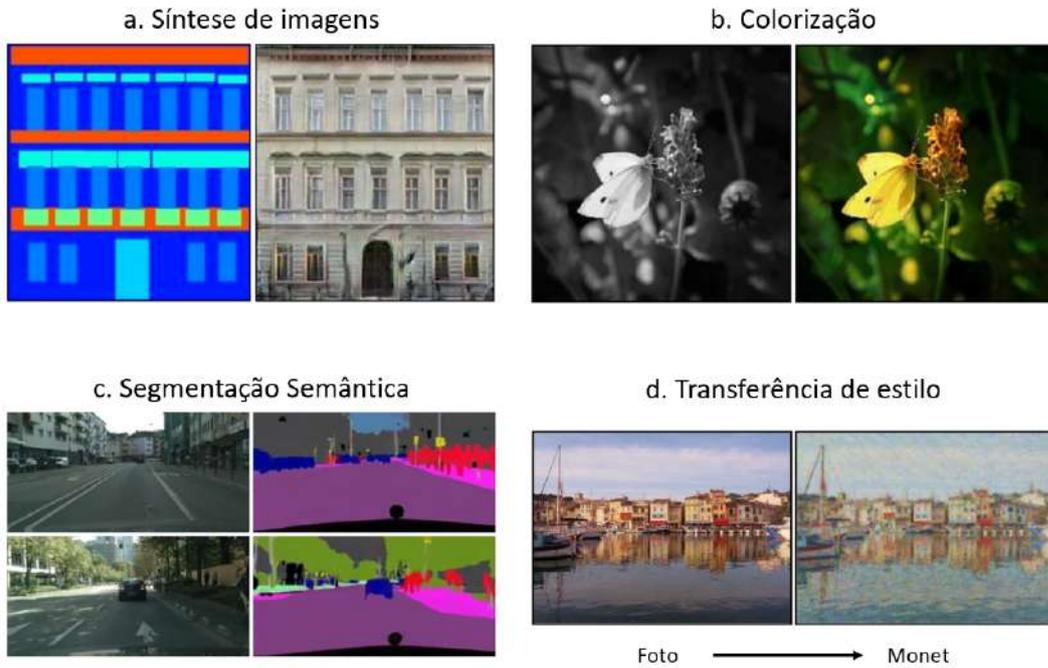


Figura 3.5: Tradução imagem-imagem unimodal: (a) síntese de imagem, (b) colorização, (c) segmentação semântica e (d) transferência de estilo [17, 62].



Figura 3.6: Tradução imagem-imagem multimodal [63].



Figura 3.7: Tradução imagem-imagem multidomínio [56].

Desse modo, uma forma adicional de classificação das redes I2I é determinada pela sua topologia [38]:

- **Domínios pareados unimodal:** tradução de imagens entre dois domínios específicos (figura 3.8a);
- **Domínios pareados multimodal:** tradução de imagens entre dois domínios, mas com múltiplas representações no domínio de destino (figura 3.8b); e
- **Multidomínio unimodal:** tradução de imagens entre múltiplos domínios, sendo realizado um treinamento independente para o mapeamento de cada par de domínios (figura 3.8c);
- **Multidomínio multimodal:** tradução de imagens entre múltiplos domínios, sendo treinado um modelo unificado que consegue lidar com as diferenças semânticas de todos os domínio em conjunto (figura 3.8d).

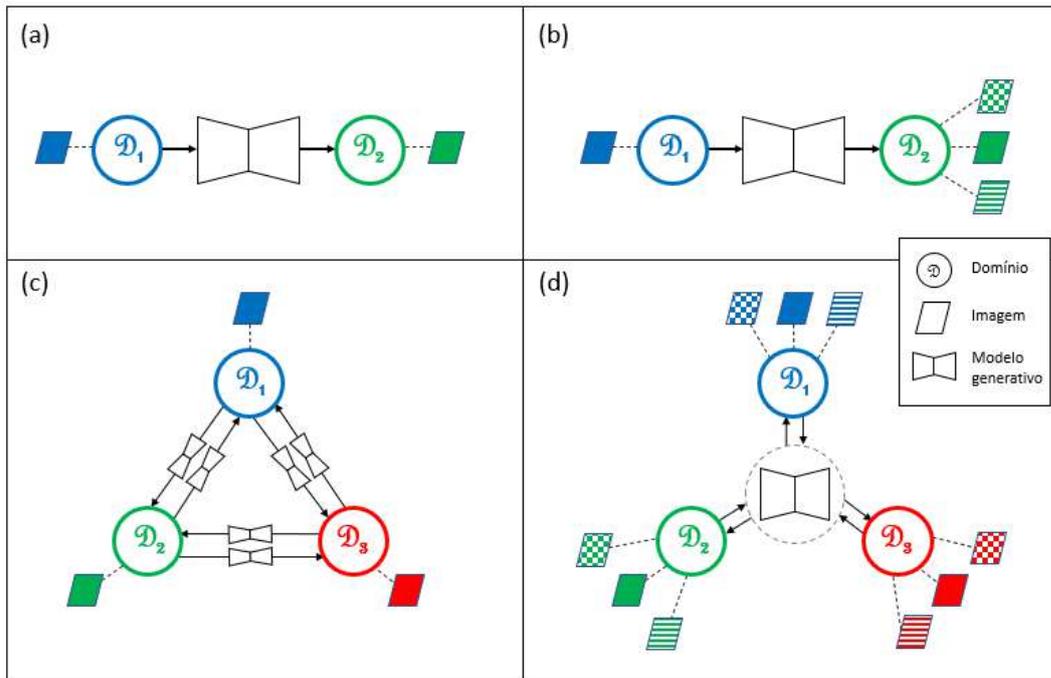


Figura 3.8: Estrutura básica das redes I2I: (a) domínios pareados unimodal, (b) domínios pareados multimodal, (c) multidomínio unimodal e (d) multidomínio multimodal.

Atualmente, há muitas redes para tradução I2I disponíveis, as quais atendem as mais diversas finalidades. Na seção 3.3.1, será descrita em detalhes a rede `pix2pix`, a qual foi selecionada para a execução deste estudo. Entretanto, o apêndice C apresenta outras redes e suas características básicas, como referência para futuras pesquisas.

3.3.1 Rede `pix2pix`

A rede `pix2pix` [17] foi desenvolvida com o objetivo de resolver tarefas de tradução I2I, através de uma arquitetura de rede convolucional generativa condicional (CGAN). Trata-se de uma rede com topologia de domínios pareados unimodal, cujo treinamento é realizado através de aprendizado supervisionado.

Diversas soluções anteriores à rede `pix2pix` adotavam arquiteturas *encoder-decoder* simples, realizando uma redução de escala (*downsampling*) até uma camada onde a dimensionalidade é mínima, ponto a partir do qual o processo é revertido (*upsampling*). Em alguns casos este “engargalamento” pode significar uma perda excessiva de informação, comprometendo a qualidade da síntese da imagem na saída. Para minimizar este efeito, a solução proposta para a rede `pix2pix` foi a de adotar uma arquitetura U-Net em seu

módulo gerador, com conexões residuais entre blocos simétricos ao centro da rede, permitindo o fluxo de informações adequado para a reconstrução da imagem.

PUC-Rio - Certificação Digital N° 2020961/CA

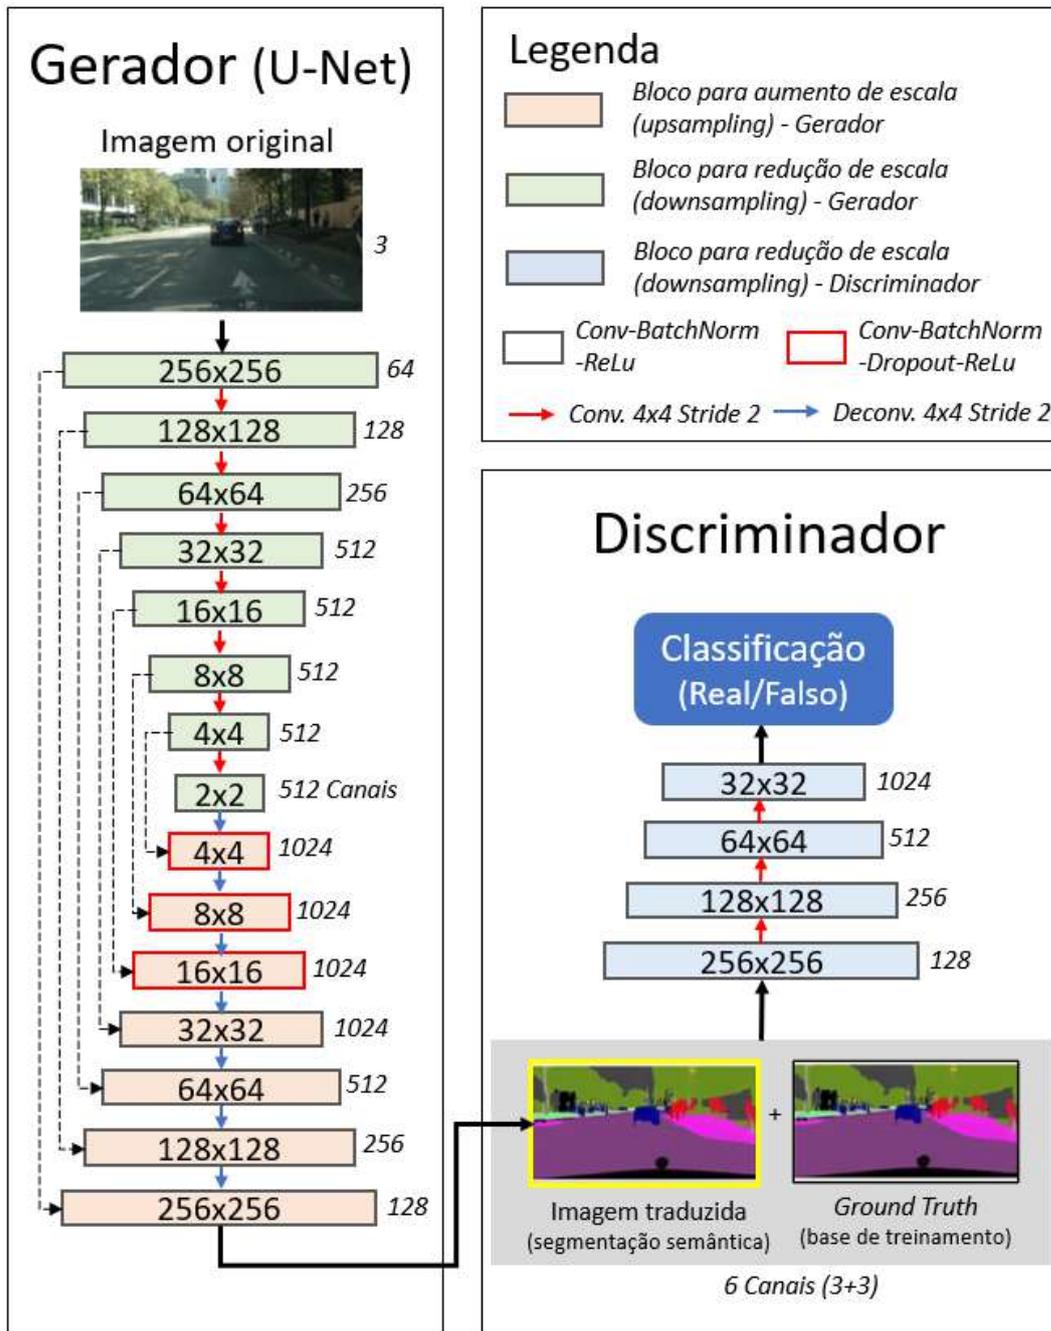


Figura 3.9: Diagrama da rede pix2pix.

A figura 3.9 apresenta o diagrama arquitetural da rede pix2pix, com detalhes sobre a composição de seus módulos e camadas. Em resumo, o gerador U-Net realiza a contração da imagem (*downsampling*, em verde) e a posterior expansão (*upsampling*, em laranja) através de blocos com filtros convolucionais, de tamanho 4x4 com *stride* 2, com conexões residuais entre blocos

simétricos. Durante a etapa de treinamento, a imagem traduzida pelo módulo gerador - na figura, um exemplo de segmentação semântica - é concatenada com a imagem correspondente da base de treinamento (*ground truth*), sofrendo então uma nova etapa de redução de dimensionalidade (*downsampling*, em azul), até ser codificada numa representação da classificação da imagem (falsa ou real). Após finalizado um processo de treinamento bem sucedido, o módulo gerador pode então ser utilizado para realizar a tradução de imagens.

Devido ao seu reconhecido bom desempenho, a rede `pix2pix`¹ foi a escolhida para ser incorporada ao processo de ajuste de histórico neste trabalho, cuja metodologia será demonstrada no capítulo 4.

¹Disponível em <https://github.com/junyanz/pytorch-CycleGAN-and-pix2pix>.

4

Metodologia de Assimilação de Dados Integrada à Tradução Imagem-imagem

O processo de assimilação de dados históricos a modelos de reservatórios pode se beneficiar da utilização de redes de aprendizado profundo (*deep learning*) para a melhoria do seu desempenho e há alguns exemplos na literatura de aplicação desta abordagem.

Uma metodologia indireta foi proposta por Arauco Canchumuni et al. [2, 3] e consiste na integração do método *ensemble smoother with multiple data assimilation* (ES-MDA) com uma rede do tipo *autoencoder*¹, de forma a realizar uma parametrização, em seu espaço latente, que permita o ajuste das fácies geológicas. Nela, o procedimento começa com o treinamento de um conjunto de realizações de fácies por meio da rede *autoencoder*, a qual aprende a identificar as principais características da malha de fácies geológicas e criar novas realizações com as mesmas características da base de treinamento, a partir de um conjunto de parâmetros representativo dos modelos de fácies, sintetizado na saída do codificador (*encoder*). Esse conjunto de parâmetros no espaço latente da rede *autoencoder* é regularizado pelo módulo codificador de forma a constituir uma representação numérica contínua das imagens de fácies, seguindo uma distribuição gaussiana, sendo esta propriedade atualizada pelo método ES-MDA durante o processo de ajuste assistido de histórico. Assim, ao final de cada iteração para atualização do modelo, a propriedade original é reconstruída pelo módulo decodificador (*decoder*), de forma que o modelo de reservatórios possa ser simulado, produzindo - ao final do ciclo de assimilação de dados - realizações de fácies ajustadas que apresentam características similares às da base de treinamento.

Por outro lado, em uma estratégia direta, proposta por Mosser et al. [34], foi realizado o processo de assimilação de dados partindo de uma rede generativa adversária (GAN) pré-treinada para representar as propriedades espaciais do modelo (\mathbf{m}) - permeabilidade, porosidade e fácies - com base no aprendizado das distribuições modeladas para caracterizar o reservatório [33]. A simulação de reservatórios é então realizada para se obter a resposta do modelo gerado $\mathbf{d} = \mathbf{g}(\mathbf{m})$, sendo avaliado o desvio entre o resultado simulado

¹Rede com arquitetura *encoder-decoder* treinada para representar em sua saída uma cópia aproximada de sua entrada.

e o dado histórico observado ($\mathbf{d} - \mathbf{d}_{\text{hist}}$). São então obtidos os gradientes deste desvio (entre observado e simulado) em relação às propriedades do modelo, os quais são então retro-propagados para corrigir os parâmetros do modelo generativo profundo, otimizando os pesos da rede, de forma que a cada iteração o modelo generativo produza realizações do reservatório que estejam mais aderentes aos dados históricos.

Apesar da abordagem direta ter apresentado bons resultados ao ajustar modelos de pequenas dimensões, o fato de a resposta simulada dos modelos de reservatório ser necessária a cada iteração de treinamento da rede generativa pode inviabilizar o processo, pois a simulação de reservatórios reais, em geral, é custosa e tende a consumir um tempo considerável. Assim, parecem ser mais promissoras as metodologias indiretas em que uma rede generativa possa ser acoplada a métodos tradicionais de ajuste assistido de histórico, como o ES-MDA, sem a necessidade de treinamento da rede generativa ao longo do processo de assimilação dos dados.

4.1

Analogia entre Imagem e Modelo de Reservatórios

Um modelo de reservatórios é uma representação numérica das características de rocha e de fluido de uma jazida de petróleo, as quais podem consistir de parâmetros que tenham uma distribuição espacial ao longo do reservatório, sendo representados no modelo como uma malha discreta de células (*grid*), como por exemplo a porosidade e a permeabilidade, ou por parâmetros escalares que têm um impacto global/regional no modelo, como a profundidade do contato óleo-água.

A estrutura matricial dos parâmetros de malha do modelo de reservatórios possui um alto grau de similaridade com a representação de uma imagem (figura 4.1), constituída por uma malha tridimensional de *pixels*, com as camadas representando a intensidade de cada uma das três cores fundamentais que definem o modelo RGB do espectro cromático: vermelho, verde e azul.

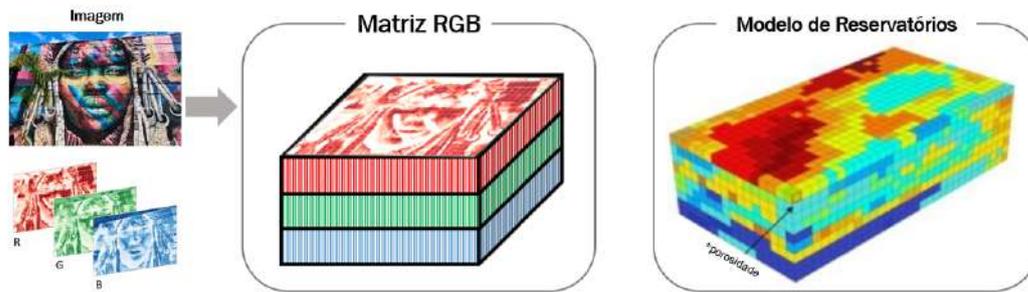


Figura 4.1: Analogia da representação em malha entre imagens e modelos de reservatórios

Portanto, esta analogia é um incentivo à investigação sobre a viabilidade da aplicação das técnicas de tradução imagem-imagem (discutidas no capítulo 3), com o objetivo de incorporá-las ao processo de ajuste assistido de histórico (apresentados no capítulo 2), melhorando a eficiência da assimilação de dados a modelos de reservatórios, refletindo assim o excelente desempenho que as redes I2I tem demonstrado em aplicações recentes.

4.2 Metodologia Proposta

Métodos de ajuste assistido de histórico baseados no filtro de Kalman, em particular o ES-MDA [11], representaram uma evolução para o problema de incorporação de dados a modelos de reservatórios. Entretanto, estes métodos são fundamentados em hipóteses gaussianas para a distribuição de probabilidades dos parâmetros a serem ajustados. Assim, há uma severa redução de eficiência quando as propriedades a serem atualizadas ao longo processo de assimilação de dados são caracterizadas por distribuições que se afastam de uma normal [2], como aquelas representadas por valores categóricos tais quais a ocorrência/ausência de fraturas no reservatório ou a propriedade de fácies geológicas.

Portanto, a metodologia que está sendo proposta (figura 4.2) consiste em adaptar uma rede generativa profunda de tradução imagem-imagem, treinando-a para, a partir de uma malha de propriedades contínuas de entrada (porosidade, permeabilidade etc), ser capaz de traduzi-las em uma propriedade categórica correlata (como as fácies) na saída da rede, realizando um processo similar à tarefa de segmentação semântica de imagens. Ao final da etapa de treinamento, o módulo gerador da rede será acoplado ao método ES-MDA de forma que a propriedade categórica possa ser sintetizada após a atualização das propriedades contínuas, a cada iteração do método, em uma abordagem

indireta, análoga ao proposto por Arauco Canchumuni et al. [2, 3].

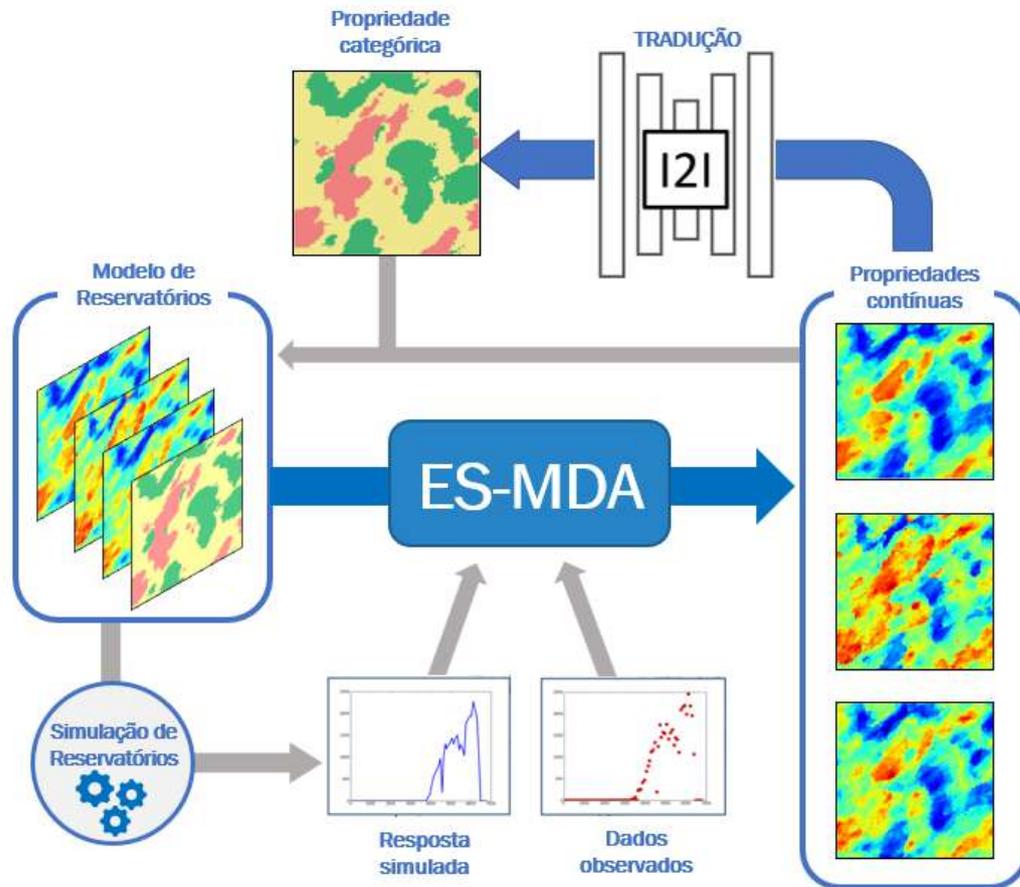


Figura 4.2: Metodologia para assimilação de dados a modelos de reservatórios integrada a redes de tradução I2I.

Neste contexto, o objetivo é que a rede seja capaz de aprender as regras de formação abstratas que caracterizam a distribuição espacial da propriedade categórica (fácies) e as correlações não-lineares que controlam a subsequente modelagem das propriedades contínuas (porosidade, permeabilidade etc), permitindo assim a resolução do problema inverso de se obter a propriedade categórica a partir das propriedades contínuas e tornando possível, portanto, a atualização indireta da propriedade categórica ao longo da assimilação de dados pelo método ES-MDA.

Uma vez que nos processos de modelagem geológica as fácies são geradas e, em sequência, são amostradas suas respectivas propriedades petrofísicas correlatas (porosidade e permeabilidade), tem-se a disposição uma base pareada de realizações geológicas para a execução da etapa de treinamento da rede I2I, sendo este um cenário favorável para arquiteturas que utilizem métodos

de aprendizado supervisionado.

Portanto, após a formalização da metodologia proposta, esta foi implementada e sua aplicação será exposta no capítulo 5.

5 Aplicação da Metodologia

Uma vez descrita a metodologia a ser aplicada, foi estruturado o estudo para promover a sua implementação e avaliação, o qual consistiu das seguintes etapas, detalhadas ao longo do presente capítulo:

- Construção dos Casos de Estudo: definição do modelo de reservatórios e geração das realizações geológicas, compondo os casos avaliados;
- Definição de Métricas para Avaliação: determinar as métricas a serem utilizadas para a quantificação dos desvios entre os dados históricos *versus* simulados e para a comparação entre propriedades dos modelos.
- Treinamento da Rede I2I: treinar a rede para realizar a tradução das propriedades contínuas (porosidade, permeabilidade) para a propriedade categórica (fácies); e
- Assimilação de Dados: integrar rede I2I treinada ao método ES-MDA e realizar o ajuste de histórico dos modelos;

5.1 Construção dos Casos de Estudo

Considerando o objetivo de incorporar dados de produção a modelos de reservatórios, foi necessário inicialmente definir o conjunto de modelos *a priori* que serão utilizados, construindo o arcabouço do modelo de simulação, as realizações de propriedades geológicas que irão compor as bases de treinamento, validação e teste da rede I2I, além do conjunto de modelos que serão alvo da simulação de reservatórios, para enfim estabelecer os casos de estudo.

5.1.1 Modelo de Reservatórios

A primeira etapa executada foi a construção de um modelo de reservatórios baseado no modelo de referência SPE9¹ [22], sendo este um modelo de simulação *black-oil*² com 24 x 25 x 15 células, contendo 25 poços produtores e um poço injetor de água.

¹Disponível em <https://www.sintef.no/projectweb/mrst/modules/ad-core/spe9/>.

²Modelo utilizado para o cálculo das propriedades dos fluidos ao longo do escoamento, no qual as fases líquida e gasosa são tratadas sem a necessidade de conhecer a composição molar de cada fase.

Entretanto, foram realizadas algumas adaptações ao modelo para melhor atender aos propósitos do estudo:

- Ampliada a resolução areal para 100 x 100 células;
- Mudança de escala na direção vertical, reduzindo o número de camadas de 15 para duas versões do modelo: com 1 ou 3 camadas;
- Consideradas 3 regiões de interação rocha-fluido distintas, sendo controladas pelas fácies, cujas curvas de permeabilidade relativa³ são apresentadas no anexo D;
- Adicionados 8 poços injetores ao modelo;

As representações tridimensional e em mapa do modelo utilizado no estudo⁴, em sua versão de 3 camadas, são apresentadas nas figuras 5.1a e 5.1b, respectivamente, populado pela saturação de água. Nelas pode-se perceber que o reservatório apresenta um mergulho para leste, com a linha de injetores posicionados no aquífero e os produtores em direção ao alto do reservatório.

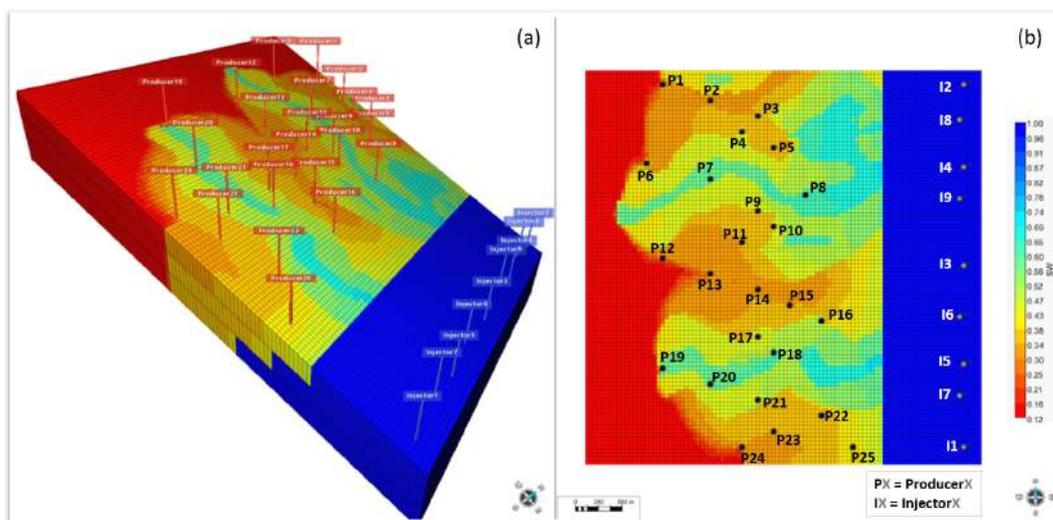


Figura 5.1: Modelo de reservatórios utilizado no estudo (versão de 3 camadas): (a) visão tridimensional; (b) visão em mapa.

As demais propriedades do modelo (como fluido, compressibilidade etc) foram mantidas as mesmas do modelo de referência, exceto as propriedades geológicas que irão compor o foco do ajuste de histórico, sendo elas a porosidade, a permeabilidade e as fácies, cuja modelagem será detalhada a seguir.

³Relação entre a permeabilidade efetiva de uma rocha e sua permeabilidade absoluta, quando parcialmente saturada por um fluido.

⁴Modelo foi construído considerando uma estrutura compatível com o simulador IMEX, desenvolvido pela *Computer Modelling Group* (CMG), o qual foi utilizado para a execução da simulação de escoamento dos modelos neste estudo.

5.1.2 Realizações Geológicas

Considerando o fluxo tradicional de modelagem geológica [58], após a construção do arcabouço estrutural (neste trabalho representado pelo modelo SPE9 adaptado), a modelagem das fácies é realizada de forma a refletir a influência do ambiente deposicional na gênese do reservatório. Em seguida, as fácies são utilizadas para condicionar a modelagem das propriedades petrofísicas, como porosidade e permeabilidade.

Entretanto, conforme metodologia proposta no capítulo 4, ao longo do processo de assimilação de dados o método ES-MDA será responsável pela atualização das propriedades contínuas (porosidade e permeabilidade) as quais em seguida serão traduzidas na propriedade categórica correspondente (fácies) pela rede I2I adaptada, num fluxo inverso ao da modelagem geológica.

Assim, para a construção dos casos de estudo, o *workflow* de modelagem geológica foi executado múltiplas vezes para construir um conjunto de realizações de {fácies, porosidade, permeabilidade} correlacionadas, numa malha de tamanho 100x100x3, compondo subconjuntos independentes para atender a propósitos específicos ao longo do estudo, como as bases de dados para treinamento, validação e teste da rede I2I, além dos modelos a serem simulados, apresentando a seguinte composição:

- 3500 amostras para a base de treinamento da rede I2I;
- 1000 amostras para a base de validação;
- 500 amostras para a base teste;
- 200 amostras representando o conjunto de modelos *a priori* (\mathbf{m}_{prior}) que serão ajustados pelo método ES-MDA ($N_m = 200$); e
- 1 amostra cuja resposta simulada será considerada o dado histórico de produção (\mathbf{d}_{hist}) que se deseja ajustar, representando portanto a referência de um reservatório “real” ($\mathbf{m}_{\mathcal{R}}$).

Como analogia para a construção das realizações geológicas foi escolhido o modelo conceitual de um sistema deposicional⁵ deltaico⁶ (figura 5.2) para

⁵Conjunto de fácies geneticamente relacionadas definido com base nas características ambientais e nos processos sedimentares que o geraram.

⁶Um delta ocorre na foz de rios, podendo ser definido como uma pequena protuberância na linha da costa formada em um ponto onde um rio deságua no oceano ou outro corpo de aquoso estático, como um lago, e é formado onde os sedimentos trazidos pelo rio formam uma estrutura em formato de leque [36].

representar o processo de formação do reservatório. De forma a conceder maior robustez à avaliação da metodologia proposta, foram construídos dois conjuntos de realizações geológicas: o cenário 1 buscou representar um modelo de reservatórios canalizado, correspondendo à região dos canais distributários⁷ do sistema (destacado em vermelho na figura 5.2b), enquanto o cenário 2 descreve um reservatório com formato de lobo deltaico⁸ (destacado em azul na figura 5.2b).

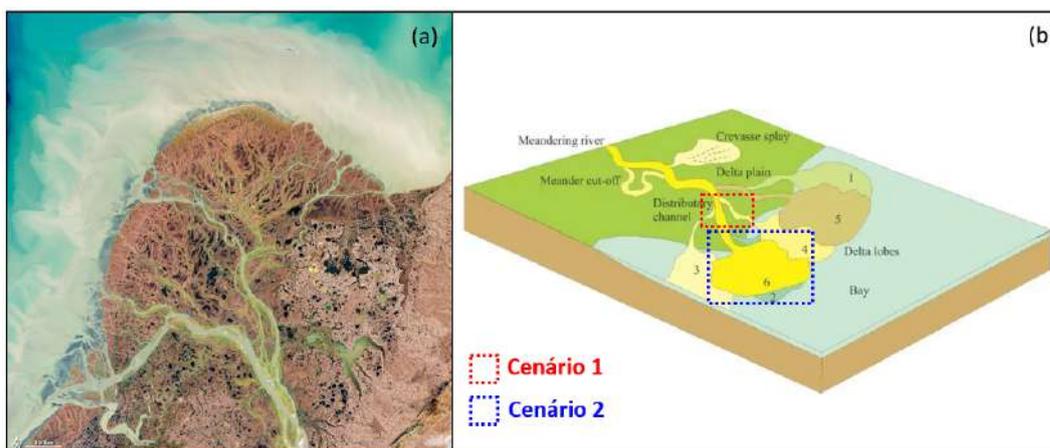


Figura 5.2: Analogia para construção dos modelos geológicos: (a) Delta do rio Yukon, Alaska (EUA) [47]; (b) Modelo conceitual do sistema deposicional deltaico, com canais distributários (cenário 1) e lobos deltaicos (cenário 2) [36].

É importante ressaltar que o sistema deposicional escolhido foi objeto apenas de inspiração para a representação das principais feições geológicas que o caracterizam (canais e lobos), durante a construção das imagens de referência, não sendo guardada associação direta entre as fácies características deste sistema com a classificação de fácies definida para a modelagem das realizações geológicas. Portanto, para atender ao objetivo específico deste estudo de avaliar a aplicação da metodologia proposta, considerou-se suficiente adotar uma representação simplificada, composta de um modelo de fácies de baixa, média e alta energia, representadas pelas classes 1, 2 e 3, respectivamente, em ambos os cenários definidos.

Técnicas distintas de modelagem de fácies foram consideradas para cada

⁷Canal divergente que flui a partir de um canal principal, sendo formado possivelmente por assoreamento do canal principal devido à deposição de sedimentos.

⁸Depósito em forma de leque, componente de um delta, formado na desembocadura de um canal.

um dos cenários, as quais estão disponíveis em aplicações comerciais⁹ de modelagem geológica:

- Cenário 1: utilizado algoritmo de simulação estatística multiponto (*Multiple-point Statistics Simulation – MPS*) que é uma técnica de modelagem de propriedades tridimensionais categóricas a partir de imagens de treinamento, as quais representam o modelo geológico conceitual, utilizadas para estimar a probabilidade de ocorrência de padrões presentes na imagem e, a partir destes, amostrar as múltiplas realizações geológicas [51]. Assim, a distribuição das fácies, mesmo que complexa, é mantida com um alto nível de detalhes sem exigir a simplificação introduzida por um modelo de variograma.
- Cenário 2: utilizado algoritmo de simulação gaussiana truncada (*Truncated Gaussian Simulation – TGS*) que é um método para distribuir um conjunto de fácies, considerando funções gaussianas aleatórias, além da sua proporção e distribuição espacial, sendo controlados por parâmetros geoestatísticos, caracterizados por um modelo de variograma, que podem ser inferidos a partir dos dados de poços com uma possível integração de dados sísmicos [4].

Assim, as fácies do cenário 1 foram modeladas a partir das imagens de treinamento apresentadas da figura 5.3 (utilizadas para a modelagem pelo método MPS), descrevendo canais com direção principal de deposição leste-oeste. Em contrapartida, as fácies do cenário 2 foram condicionadas a representar a feição de um lobo com sentido principal de deposição sudeste-noroeste, cujos mapas de tendência (para a modelagem TGS) são apresentados na figura 5.4.

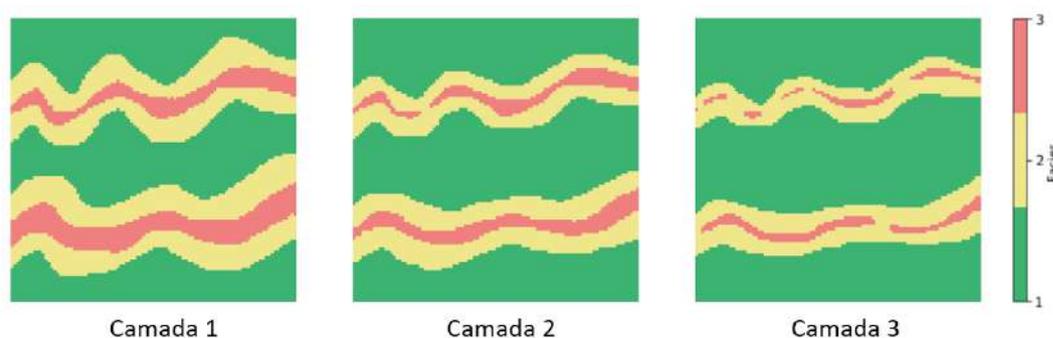


Figura 5.3: Imagens de treinamento por camada para modelagem geológica das fácies do Cenário 1 através do método MPS.

⁹A construção das realizações geológicas deste estudo foi realizada através do *software* de modelagem geológica *Petrel* (SLB).

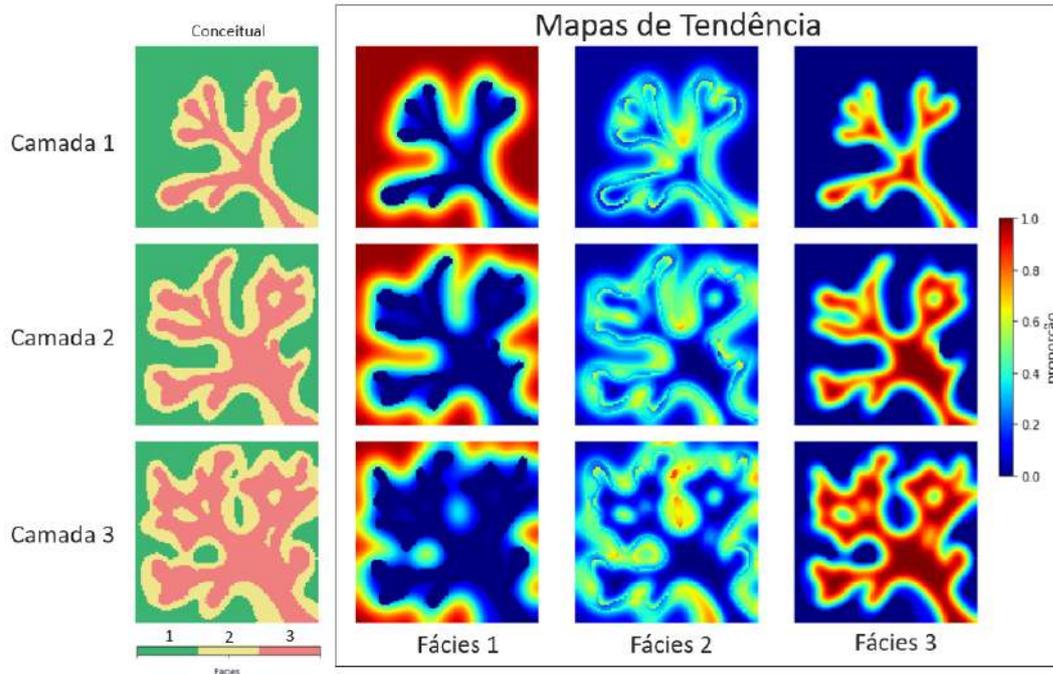


Figura 5.4: Mapas de tendência de fácies por camada para modelagem geológica do Cenário 2 através do método TGS

Após amostragem das realizações de fácies, iniciou-se a etapa de modelagem das propriedades petrofísicas, porosidade e permeabilidade, condicionadas pelas fácies. As realizações foram geradas através de simulação gaussiana sequencial e os parâmetros das distribuições são descritos na tabela 5.1. As figuras 5.5 e 5.6 apresentam os histogramas das propriedades petrofísicas dos cenários 1 e 2, respectivamente, tendo sido considerado um maior desvio padrão nas distribuições gaussianas do cenário 2.

Tabela 5.1: Parâmetros da distribuição gaussiana truncada para modelagem das propriedades petrofísicas.

Cenário	Propriedade	Fácies (Classe)	Média	Desvio Padrão	Mínimo	Máximo
1	Porosidade (%)	Baixa Energia (1)	7	1	4	10
		Média Energia (2)	15	1	6	16
		Alta Energia (3)	11	1	10	20
	Permeabilidade (mD)	Baixa Energia (1)	30	10	10	150
		Média Energia (2)	300	100	20	2000
		Alta Energia (3)	2000	1000	50	10000
2	Porosidade (%)	Baixa Energia (1)	7	3	4	10
		Média Energia (2)	11	3	6	16
		Alta Energia (3)	15	3	10	20
	Permeabilidade (mD)	Baixa Energia (1)	30	50	10	150
		Média Energia (2)	300	200	20	2000
		Alta Energia (3)	2000	1500	50	10000

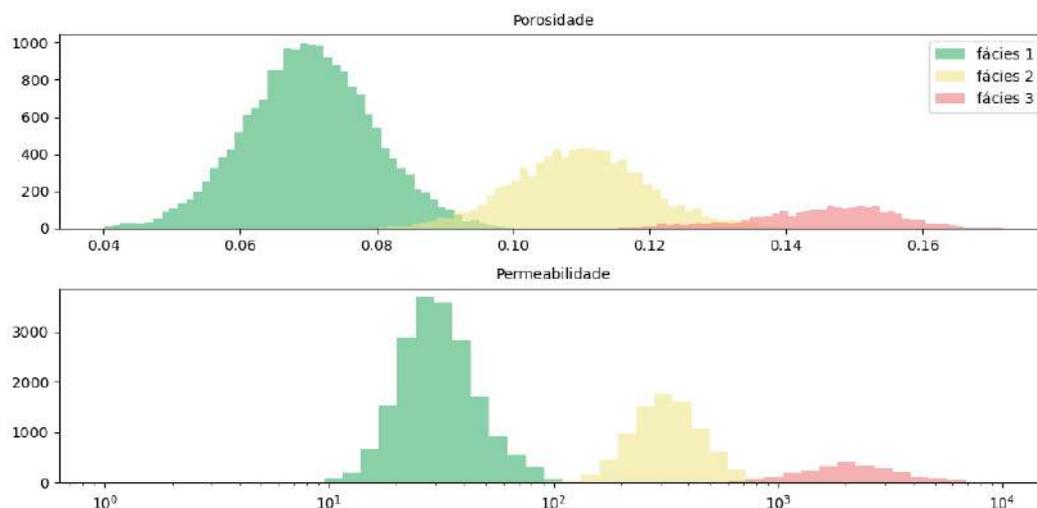


Figura 5.5: Histograma das propriedades petrofísicas do cenário 01.

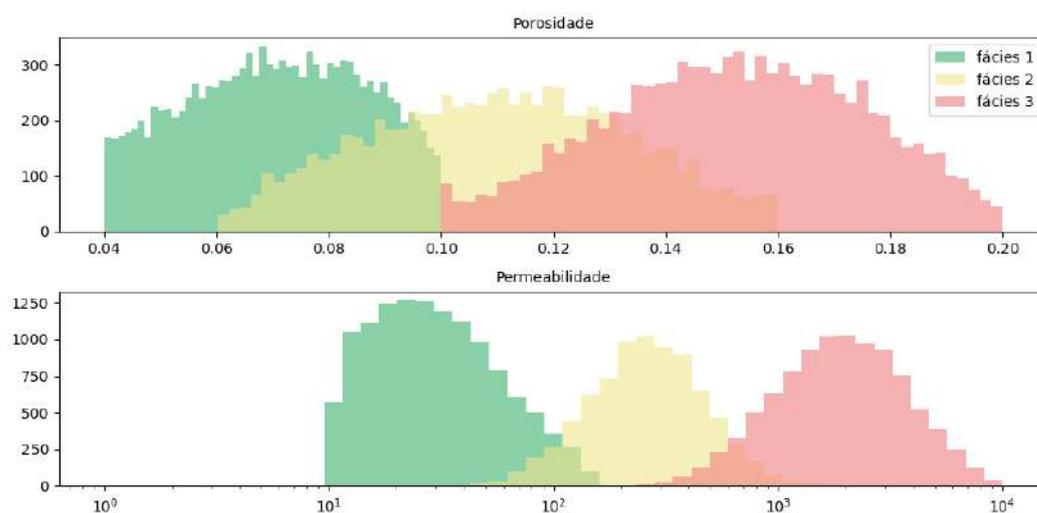


Figura 5.6: Histograma das propriedades petrofísicas do cenário 02.

PUC-Rio - Certificação Digital N° 2020961/CA

5.1.3 Mudança de Escala

Em geral, os modelos geológicos são construídos em uma malha com um grande refinamento vertical, de forma a representar o detalhamento observado nas amostras de rocha, testemunhos e perfis de poços.

Assim, é comum que essa malha sofra um processo de mudança de escala (*upscaling*), mostrado na figura 5.7, para ser representada no modelo de simulação, de forma a reduzir o número total de células, proporcionando

uma redução do tempo de execução do simulador de reservatórios.

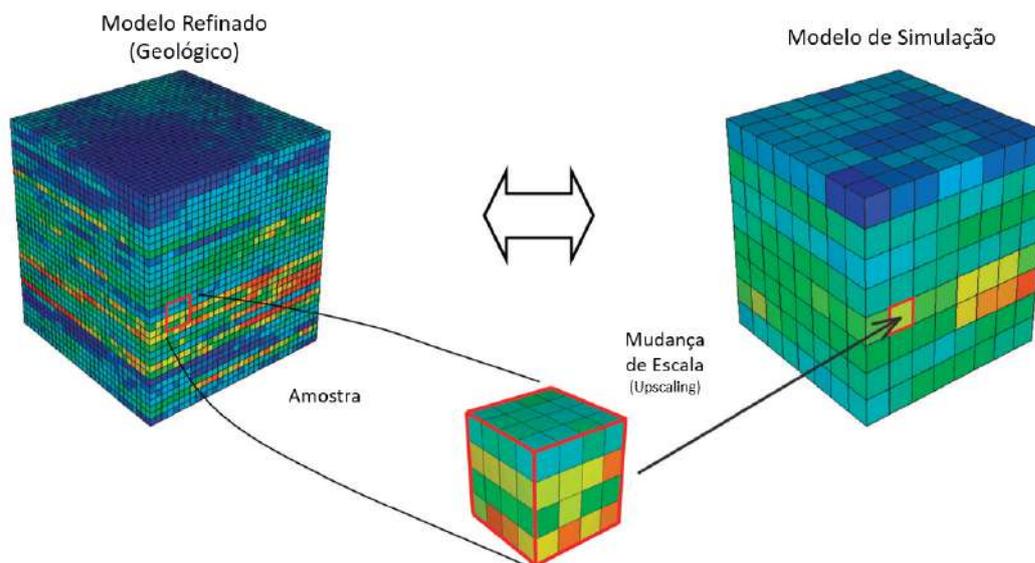


Figura 5.7: Mudança de escala (*upscaling*) em modelos de reservatórios (adaptado de [49]).

Foi então realizado o *upscaling* vertical dos modelos de 3 para 1 camada. Cada propriedade possui um método distinto para mudança de escala (figura 5.8), sendo necessário no caso da permeabilidade considerar uma distinção entre a permeabilidade horizontal e vertical após o *upscaling*. Os métodos utilizados foram os seguintes:

- Fácies: valor mais frequente da classe (*most of*), entre as 3 camadas, ponderado pela espessura da camada;
- Porosidade: média ponderada pela espessura da camada.
- Permeabilidade horizontal: média aritmética.
- Permeabilidade vertical: média de potência, com expoente 0.01.

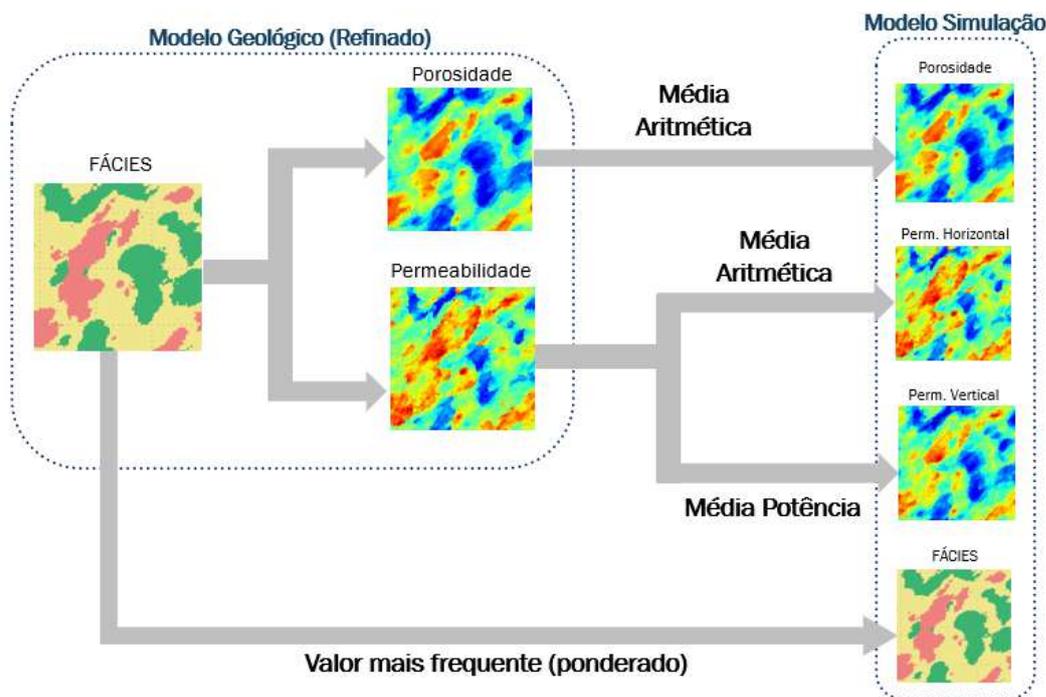


Figura 5.8: Métodos de (*upscaling*) por propriedade.

PUC-Rio - Certificação Digital N° 2020961/CA

5.1.4 Casos de Estudo

Considerando os modelos de reservatórios construídos, foram propostos alguns casos de estudo para serem avaliados, considerando os cenários geológicos 1 e 2, além das suas representações refinada (3 camadas) e após *upscaling* (1 camada), sendo descritos na tabela 5.2:

Tabela 5.2: Casos de Estudo.

Caso	Conceitual Geológico	Upscaling	Camadas	Parâmetros de Ajuste (ES-MDA)
1A	canais	Sim	1 ^(a)	porosidade, permeabilidades horizontal e vertical
1B	canais	Não	3	porosidade e permeabilidade horizontal
2A	lobos deltaicos	Sim	1 ^(a)	porosidade, permeabilidades horizontal e vertical
2B	lobos deltaicos	Não	3	porosidade e permeabilidade horizontal

^(a)Modelo de simulação representado com duas camadas iguais para captar efeitos da permeabilidade vertical.

Por fim, temos as bases de realizações geológicas construídas para cada um dos casos. As amostras de algumas destas realizações são apresentadas nas figuras 5.9 (fácies), 5.10 (porosidade) e 5.11 (permeabilidade horizontal).

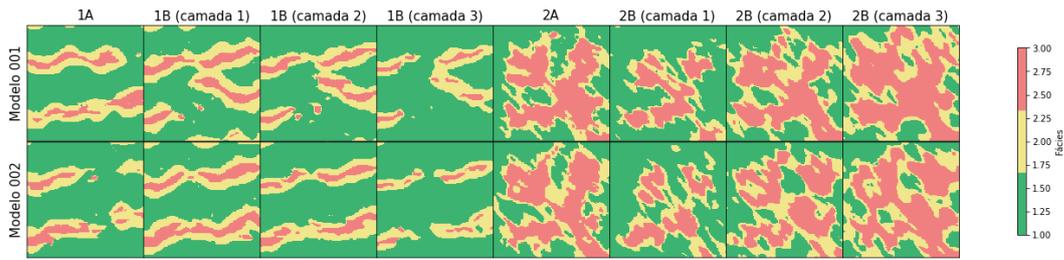


Figura 5.9: Amostras das realizações de fácies para cada caso de estudo.

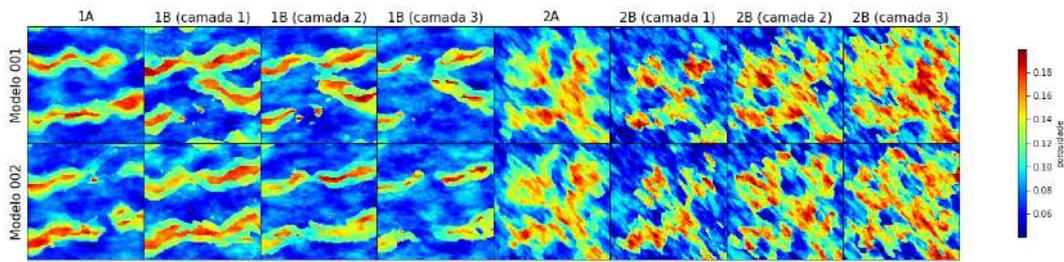


Figura 5.10: Amostras das realizações de porosidade para cada caso de estudo.

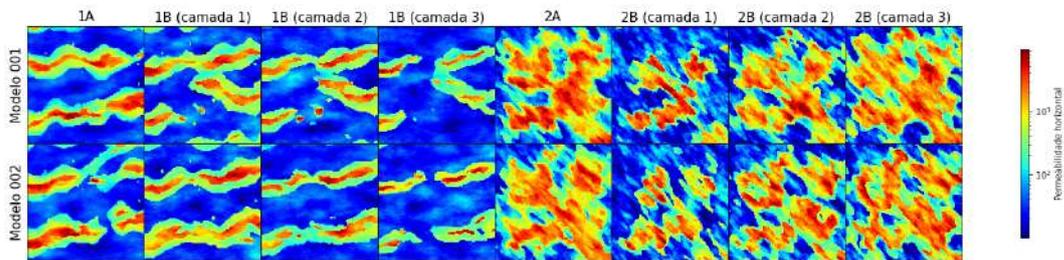


Figura 5.11: Amostras das realizações de permeabilidade horizontal para cada caso de estudo.

5.1.5

Representação das Propriedades Geológicas para a Rede I2I

Conforme descrito na seção 3.3.1, a rede `pix2pix` recebe como entrada e sintetiza na saída de seu módulo gerador uma imagem, que consiste numa representação matricial de três canais correspondendo aos valores associados às cores vermelho, verde e azul (RGB).

Assim, para os casos de estudo cujos modelos sofreram *upscaling* (1 camada), será replicada a estrutura de uma imagem, com o primeiro canal representando a porosidade (ϕ), o segundo canal correspondendo à permeabilidade horizontal (k_h) e o terceiro canal à permeabilidade vertical (k_v), conforme

figura 5.12a. Para o modelo de reservatórios refinado (3 camadas), adotou-se a estratégia de representar cada canal pelo $\log(k)/\phi$ de cada camada do modelo de reservatórios (figura 5.12b), de forma a não modificar a topologia da rede. Antes da montagem das matrizes, as propriedades petrofísicas foram normalizadas em ambos os casos.

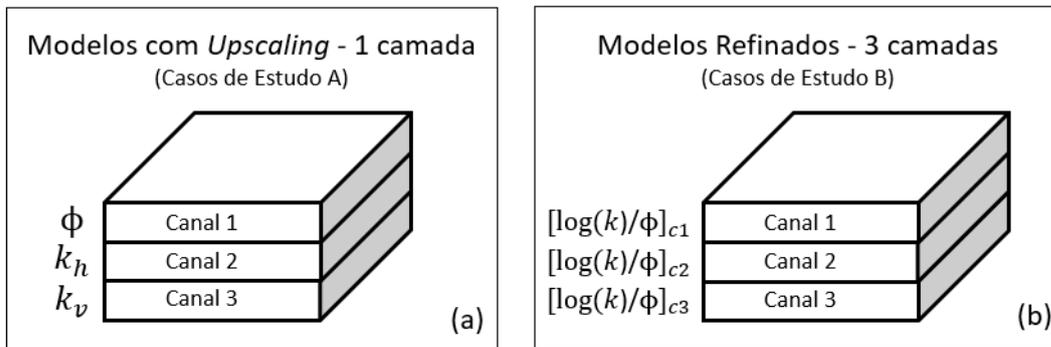


Figura 5.12: Representação matricial das propriedades petrofísicas para a rede: (a) modelo com *upscaling*; (b) modelo refinado.

A representação das fácies na saída da rede também é distinta a depender do cenário. Como a rede também gera uma saída de 3 canais, nos casos onde os modelos possuem 1 camada definiu-se a representação da saída como cada canal sendo representado exclusivamente por uma única classe de fácies. Assim, por exemplo, no canal 3 as células classificadas como fácies 3 no modelo teriam valor 1 e as demais classes teriam valor 0, repetindo esse padrão para os demais canais. Portanto, a classe de fácies de uma célula na saída é representado pelo canal de maior valor. Já para os casos com modelos refinados, a representação das fácies foi definida célula por célula, com as fácies 1, 2 e 3, sendo codificados pelos valores 0, 0.5 e 1, respectivamente, sendo definidos os limiares entre classe no ponto médio entre duas classes adjacentes (0.25 e 0.75).

5.2 Métricas de Avaliação

De forma a avaliar a efetividade do método, foram selecionadas algumas métricas para auxiliar na análise dos resultados, dentre as quais:

- Desvio Médio Normalizado dos Dados de Históricos;
- Distância L1;
- Índice de Similaridade Estrutural (SSIM);
- Matriz de Confusão.

5.2.1

Desvio Médio Normalizado dos Dados de Históricos

A aderência da resposta dos modelos aos dados de produção será quantificada através do cálculo do desvio médio normalizado dos dados de históricos ($\mathcal{O}(\mathbf{m})$), derivada da equação 2-3, sendo esta uma função objetivo que tende a valores mínimos ao se reduzir a diferença entre os dados simulados ($\mathbf{g}(\mathbf{m})$) e os dados históricos (\mathbf{d}_{hist}), descrita por:

$$\mathcal{O}(\mathbf{m}_j^\ell) = \frac{1}{2N_d} (\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m}_j^\ell))^T \mathbf{C}_D^{-1} (\mathbf{d}_{hist} - \mathbf{g}(\mathbf{m}_j^\ell)). \quad (5-1)$$

5.2.2

Distância L1

A distância L1 (ou distância *Manhattan* [24]) corresponde ao somatório do valor absoluto das diferenças elemento a elemento de dois vetores \mathbf{p}_i , ou seja:

$$d_{L1}(\mathbf{p}_1, \mathbf{p}_2) = \sum_{i=1}^n |\mathbf{p}_1 - \mathbf{p}_2| \quad (5-2)$$

Portanto, no contexto de imagens, esta é uma comparação *pixel a pixel*, correspondendo a uma quantificação relacionada ao nível 0 de complexidade (dados brutos), descrito no capítulo 3, cuja interpretação da métrica é a de que menores valores de L1 correspondem a uma maior similaridade entre imagens.

Neste trabalho, a métrica será utilizada para comparar as matrizes que representam as “imagens” das fácies geológicas. Uma vez que as fácies foram ordenadas de 1 a 3 correspondendo a ambientes deposicionais variando de baixa à alta energia, haverá uma penalização maior quando houver divergência entre fácies de alta (fácies 3) e baixa (fácies 1) energia do que entre fácies intermediárias (fácies 2) com as demais, o que é desejável neste caso.

5.2.3

SSIM

O índice de similaridade estrutural (*Structural Similarity Index Measure* - SSIM) é uma métrica comparativa que considera o caráter perceptual de formação das imagens, considerando aspectos como [53]:

- Estrutura: estimado em função da covariância entre as imagens ($\sigma_{\mathbf{p}_1\mathbf{p}_2}$)
- Contraste: estimado em função do desvio padrão das imagens ($\sigma_{\mathbf{p}_1}$ e $\sigma_{\mathbf{p}_2}$)
- Luminância: estimado em função das médias das imagens ($\mu_{\mathbf{p}_1}$ e $\mu_{\mathbf{p}_2}$)

Assim, o SSIM pode ser calculado através da seguinte equação:

$$SSIM(\mathbf{p}_1, \mathbf{p}_2) = \frac{(2\mu_{\mathbf{p}_1}\mu_{\mathbf{p}_2} + (LK_1)^2)(2\sigma_{\mathbf{p}_1\mathbf{p}_2} + (LK_2)^2)}{(\mu_{\mathbf{p}_1}^2 + \mu_{\mathbf{p}_2}^2 + (LK_1)^2)(\sigma_{\mathbf{p}_1}^2 + \sigma_{\mathbf{p}_2}^2 + (LK_2)^2)} \quad (5-3)$$

onde L é diferença entre o valor máximo e mínimo da matriz de *pixels* (255 para escala de cinza) e as constantes K_1 e K_2 incluídas para evitar instabilidades caso as médias e variâncias se aproximem de zero (sendo considerados neste estudo os valores de 0.01 e 0.03, respectivamente).

Para fins de interpretação da métrica, este indicador tenderá ao valor 1 quanto maior a similaridade entre as imagens, sendo esta uma métrica relacionada ao nível 1 de complexidade (atributos primitivos), conforme abordado no capítulo 3.

5.2.4 Matriz de Confusão

Uma matriz de confusão (ou matriz de erro)[50] é uma representação tabular frequentemente utilizada para organizar e exibir o desempenho de algoritmos voltados para predição em problemas de classificação. Nela, as linhas representam as instâncias referentes às classes reais, enquanto as colunas representam as classes preditas.

Para este trabalho serão construídas matrizes de confusão com um esquema similar ao da figura 5.13, comparando as fácies do modelo de referência com o conjunto de modelos aos quais os dados de produção serão assimilados, para todas as células dos modelos.

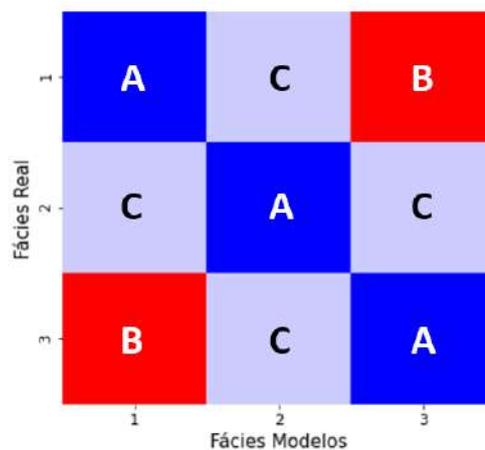


Figura 5.13: Matriz de confusão

Sendo desejável que os modelos avaliados se aproximem do modelo que

originou os dados, espera-se que os valores da diagonal principal da matriz (elementos A na figura 5.13) aumentem ao final do processo de ajuste de histórico, pois estas regiões representam células dos modelos que possuem a mesma classificação de fácies do reservatório de referência. Adicionalmente, deseja-se que os valores dos elementos B da figura se reduzam, pois estes representam diferenças entre classes com características muito distintas (fácies 1 e 3). Espera-se também que os valores em C se reduzam, pois se tratam de erros de classificação, entretanto estes tem menor relevância (quando comparados a B), por representarem fácies adjacentes, podendo as fácies 2 serem consideradas uma transição entre as fácies baixa (1) e alta energia (3).

5.3

Treinamento das Redes de Tradução I2I

Finalizado o planejamento do estudo, foi dado início à etapa de treinamento das redes de tradução I2I. Conforme descrito na seção 5.1.2, os conjuntos de realizações geológicas foram divididos em bases de treinamento, validação e teste.

O algoritmo de otimização estocástica que foi utilizado durante o processo de aprendizado da rede foi o Adam [23], com taxa de aprendizado inicial (*learning rate*) de 0.0002 e com os termos de *momentum* de primeira (β_1) e de segunda ordem (β_2) iguais a 0.5 e 0.999, respectivamente.

O treinamento das redes GAN é uma tarefa desafiadora, pois, devido a sua arquitetura promover uma competição entre redes adversárias, esses modelos requerem a minimização de uma função objetivo conjunta, que pode ser comparada à busca por um estado de equilíbrio, em um espaço de otimização de grande dimensionalidade e altamente não convexo [7].

Portanto, para definir o momento de interrupção do treinamento da rede foi adotada a estratégia de se salvar a rede treinada em determinadas épocas e avaliar o comportamento da base de teste, uma vez que o comportamento da métrica de avaliação (neste caso a distância L1) para a base de validação apresentou um declínio contínuo (figura 5.14), não demonstrando uma reversão ao longo das épocas, o qual seria o ponto natural para interrupção do treino em outros tipos de rede para evitar o problema de *overfitting*.

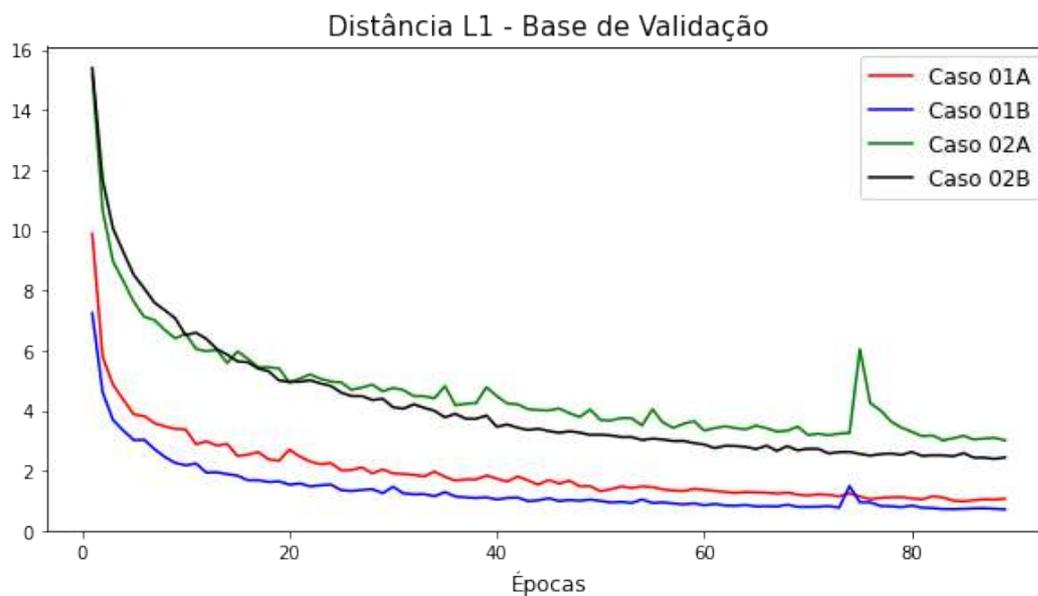


Figura 5.14: Distância L1 média da base de validação ao longo das épocas de treinamento

Desse modo, foi calculada a métrica de avaliação considerando as amostras base de teste e o resultado pode ser verificado através dos *boxplots* ao longo das épocas de treinamento mostrados nas figuras 5.15-5.18. Os resultados dos casos de estudo 1A (figura 5.15) e 1B (figura 5.16) apresentaram valores menores de L1 do que os casos 2A (figura 5.17) e 2B (figura 5.18), uma vez que o modelo geológico do cenário 01 representa um contexto de canais, onde a maior parte da imagem está sujeita a um único tipo de fácies (baixa energia), tornando mais fácil a sua previsão pela rede do que os lobos amalgamados do cenário 02. Apesar de não haver um ponto de reversão claro, considerou-se que o treinamento atingiu uma estabilidade para o cenário 01 a partir da época 50 e para o cenário 02 na época 70 para o caso de estudo 2A e 75 para o caso de estudo 2B. Portanto, estas foram as redes utilizadas para o restante do estudo.

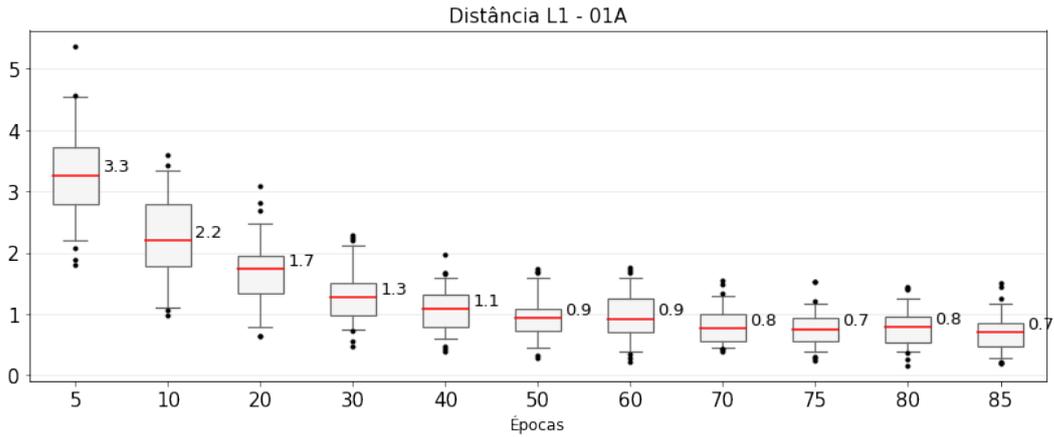


Figura 5.15: *Boxplot* da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 1A

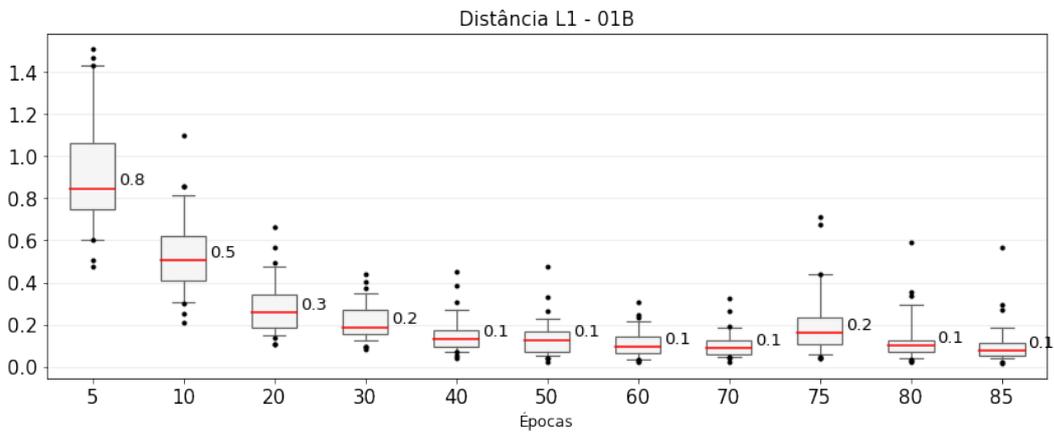


Figura 5.16: *Boxplot* da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 1B

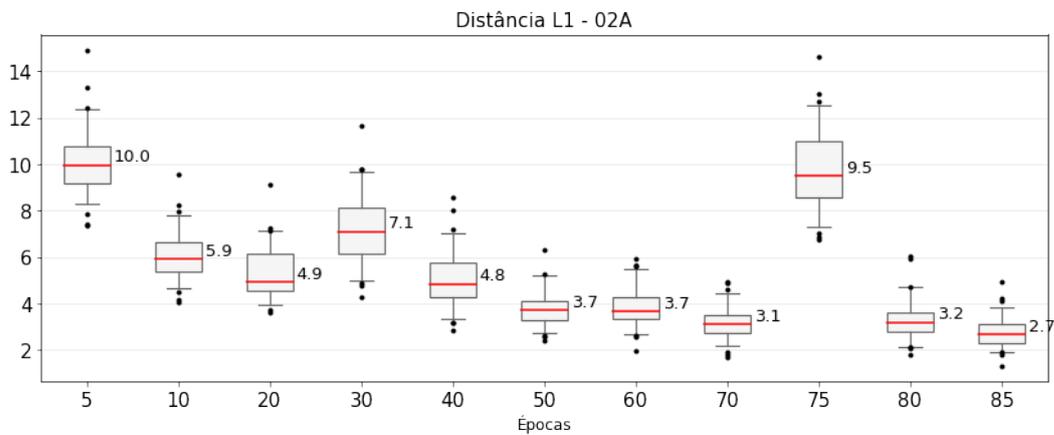


Figura 5.17: *Boxplot* da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 2A

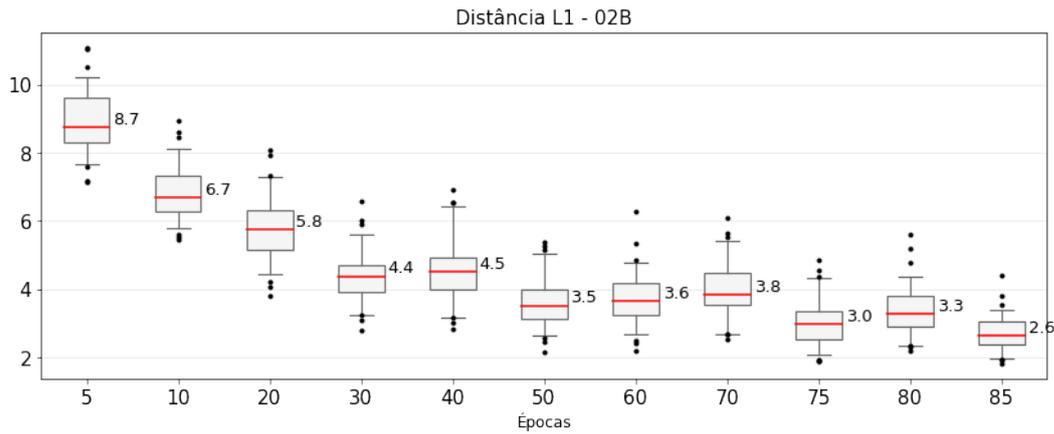


Figura 5.18: *Boxplot* da distância L1 da base de teste ao longo das épocas de treinamento da rede do caso de estudo 2B

A figura 5.19 mostra a comparação entre as imagens de fácies da base de teste (*ground truth*) e suas respectivas imagens traduzidas pela rede, de dois modelos em cada um dos casos de estudo. As redes foram capazes de aprender, durante o treinamento, as regras abstratas para permitir a tradução das propriedades petrofísicas em fácies, não perdendo a capacidade de generalização ao executar a tarefa para a base de teste.

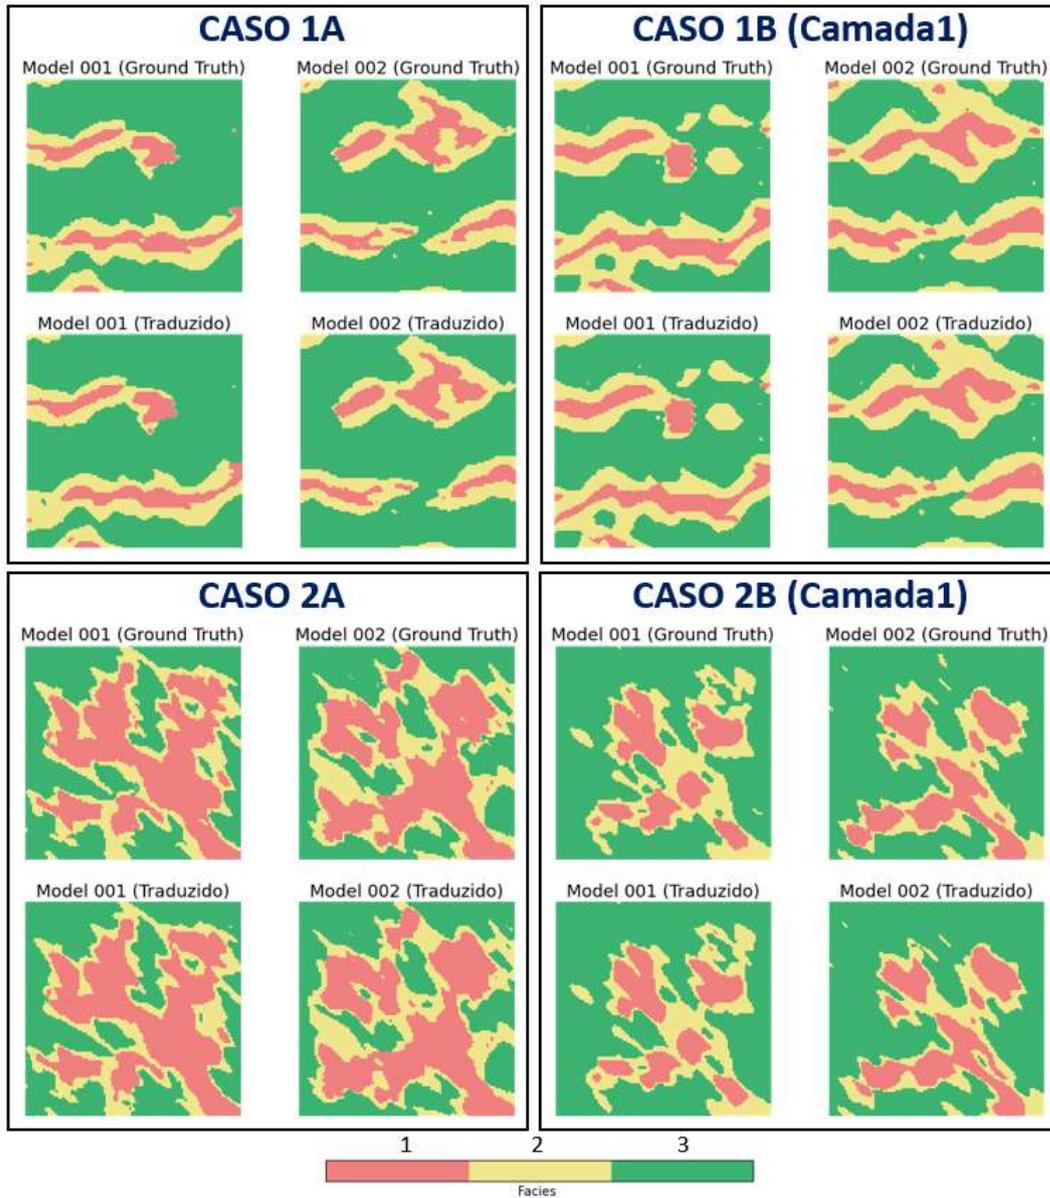


Figura 5.19: Comparação entre as imagens de fácies da base de teste (*ground truth*) e suas respectivas imagens traduzida pela rede.

5.4

Assimilação de Dados

Finalizada a a etapa de treinamento das redes I2I, estas foram integradas ao método ES-MDA (2.2.1) e o ajuste assistido de histórico foi realizado utilizando a metodologia proposta. Para isso, inicialmente o modelo de referência ($\mathbf{m}_{\mathcal{R}}$) foi simulado, sendo seu resultado considerado como a representação do conjunto de dados históricos (\mathbf{d}_{hist}) a serem ajustados, constituindo-se das vazões de óleo água e gás dos 25 poços produtores, das vazões de água injetada pelos 9 poços injetores, além das pressões de fundo de todos os 34

poços. De forma a representar os erros de medição que estariam presentes em um dado real, foi adicionado ao dado um erro aleatório com distribuição normal truncada em $[-1, 1]$, com média igual a zero e variância igual a um, multiplicado por um valor de tolerância específico para cada tipo de dado.

O processo de incorporação de dados histórico foi então realizado considerando 6 etapas de assimilação para o método ES-MDA ($N_a = 6$). Foi aplicada a técnica de localização da covariância (seção 2.2.2), considerando uma região de influência circular ao redor dos poços, com raio correspondendo a 30 células ($L_1 = L_2 = 30, \theta = 0$). Terminada esta fase, o desempenho da metodologia foi avaliado tanto em relação à aderência da resposta simulada aos dados históricos de produção quanto na qualidade dos modelos ajustados (modelos *a posteriori*), realizando a apuração e análise das métricas definidas na seção 5.2, além da inspeção visual dos resultados (curvas de produção e mapas de propriedades do modelo).

5.4.1

Análise dos Dados de Produção

A incorporação dos dados históricos de produção aos modelos pode ser avaliada através do comportamento da função objetivo ao longo das iterações para assimilação de dados, a partir do conjunto de modelos iniciais (modelos *a priori*). Assim, o desvio médio normalizado dos dados de históricos (seção 5.2.1) de todo o conjunto de modelos foi calculado, sendo apresentado nos *boxplots* das figuras 5.20 a 5.23, correspondendo aos casos de estudo apresentados na seção 5.1.4. Estes revelam que em todos os casos ocorreu a redução gradual da função objetivo ao longo das iterações, com os modelos *a posteriori* apresentando resultados substancialmente melhores do que os modelos *a priori*.

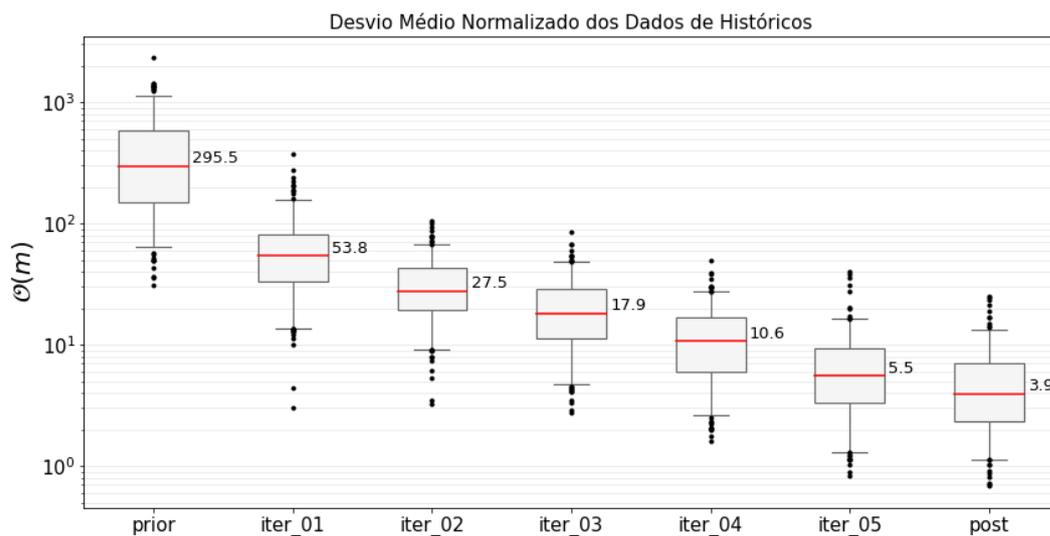


Figura 5.20: *Boxplot* do desvio médio normalizado dos dados de históricos para o caso de estudo 1A.

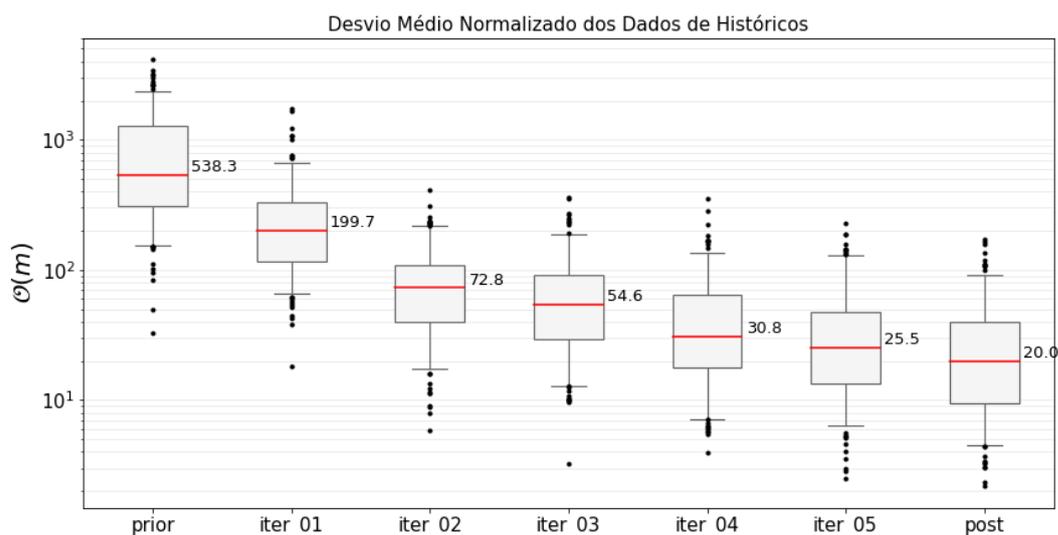


Figura 5.21: *Boxplot* do desvio médio normalizado dos dados de históricos para o caso de estudo 1B.

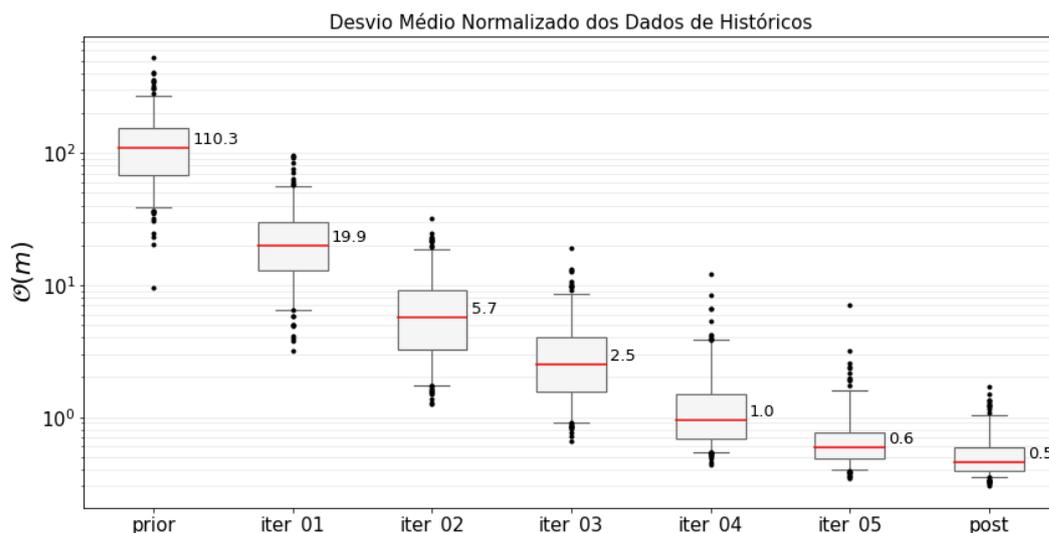


Figura 5.22: *Boxplot* do desvio médio normalizado dos dados de históricos para o caso de estudo 2A.

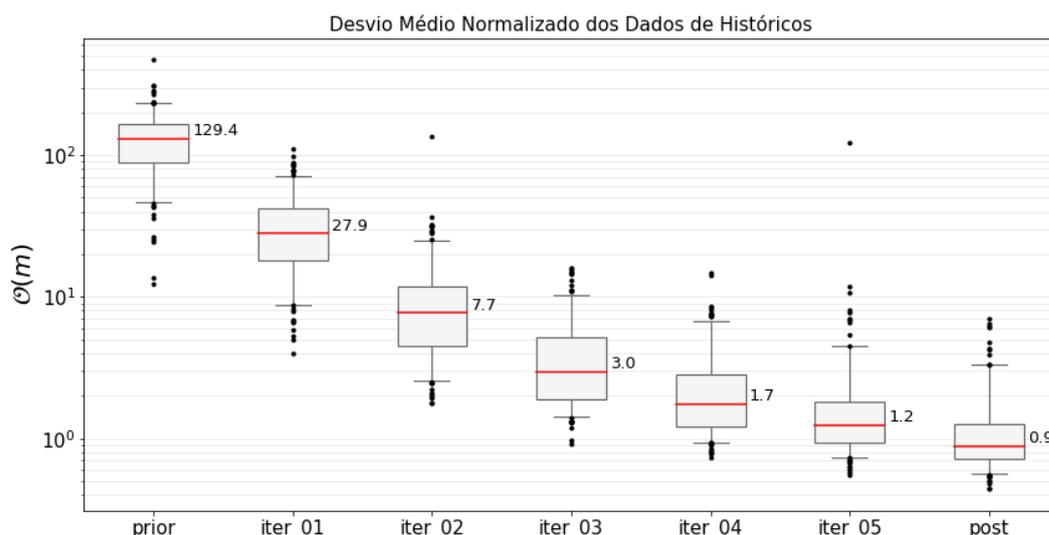


Figura 5.23: *Boxplot* do desvio médio normalizado dos dados de históricos para o caso de estudo 2B.

PUC-Rio - Certificação Digital N° 2020961/CA

Estes resultados podem ser atestados através da inspeção visual das curvas de produção dos modelos *a priori* e *a posteriori* quando comparados aos dados de produção que foram assimilados ao longo do processo. As figuras 5.24 a 5.27 apresentam os resultados do ajuste de histórico de produção de óleo, água, gás e de pressão de fundo para um dos poços produtores (*Producer1*), sendo que os dados históricos estão representados em vermelho, os resultados simulados do conjunto de modelos iniciais em cinza, o conjunto de modelos

ajustados em ciano e o modelo que apresentou o melhor ajuste global em azul escuro.

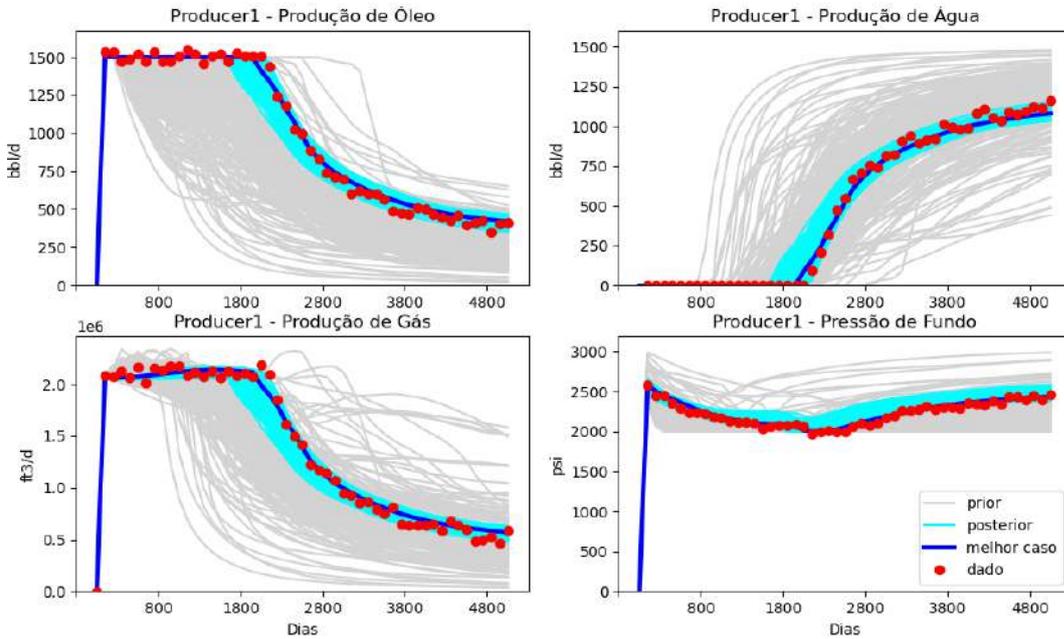


Figura 5.24: Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “*Producer1*” para o caso de estudo 1A.

PUC-Rio - Certificação Digital N° 2020961/CA

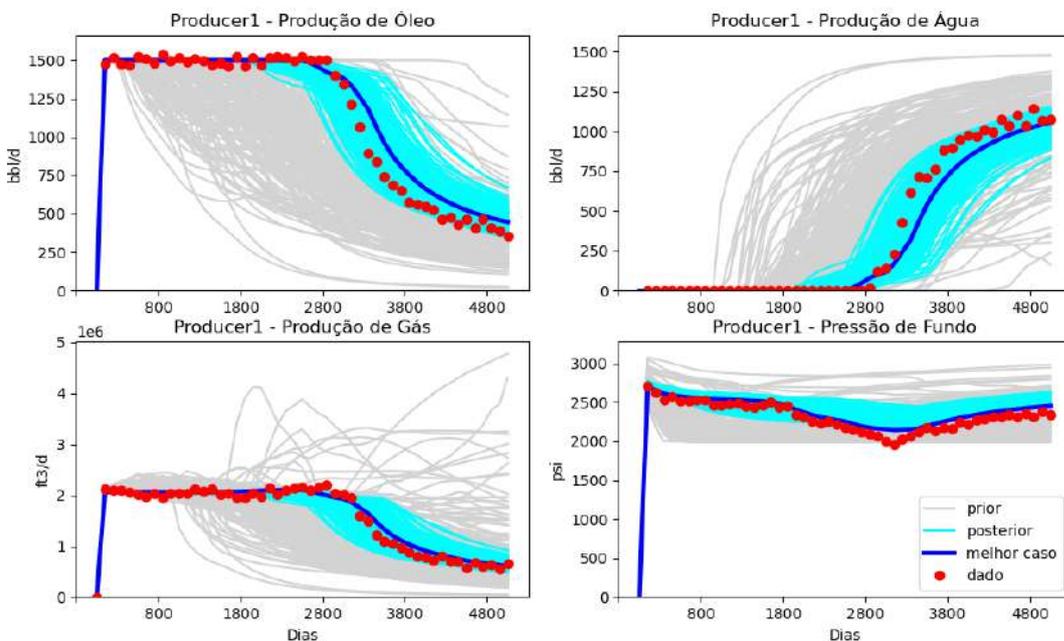


Figura 5.25: Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “*Producer1*” para o caso de estudo 1B.

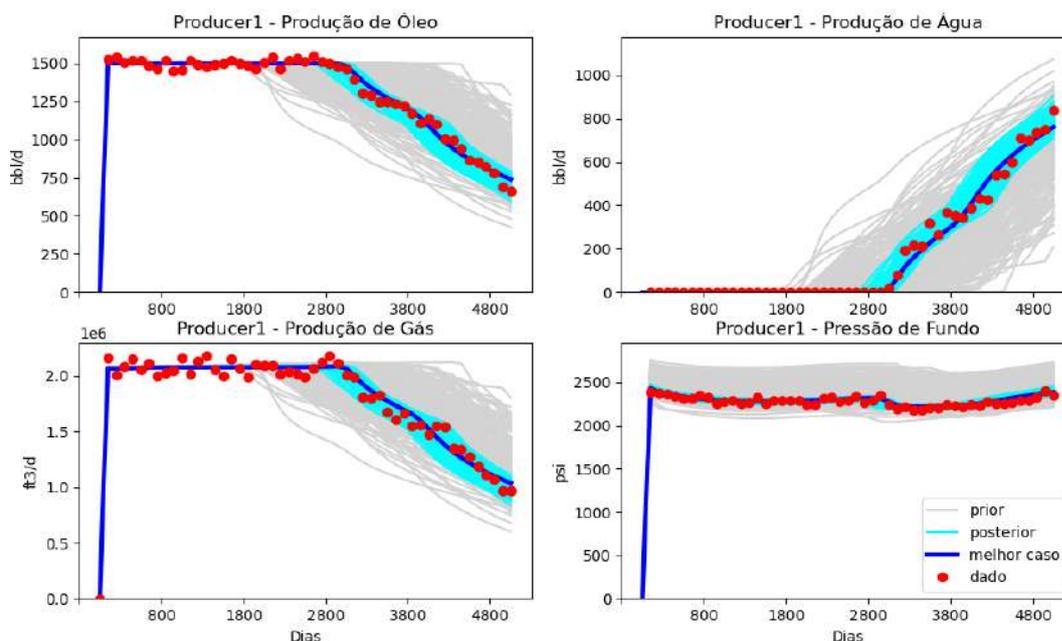


Figura 5.26: Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “*Producer1*” para o caso de estudo 2A.

PUC-Rio - Certificação Digital N° 2020961/CA

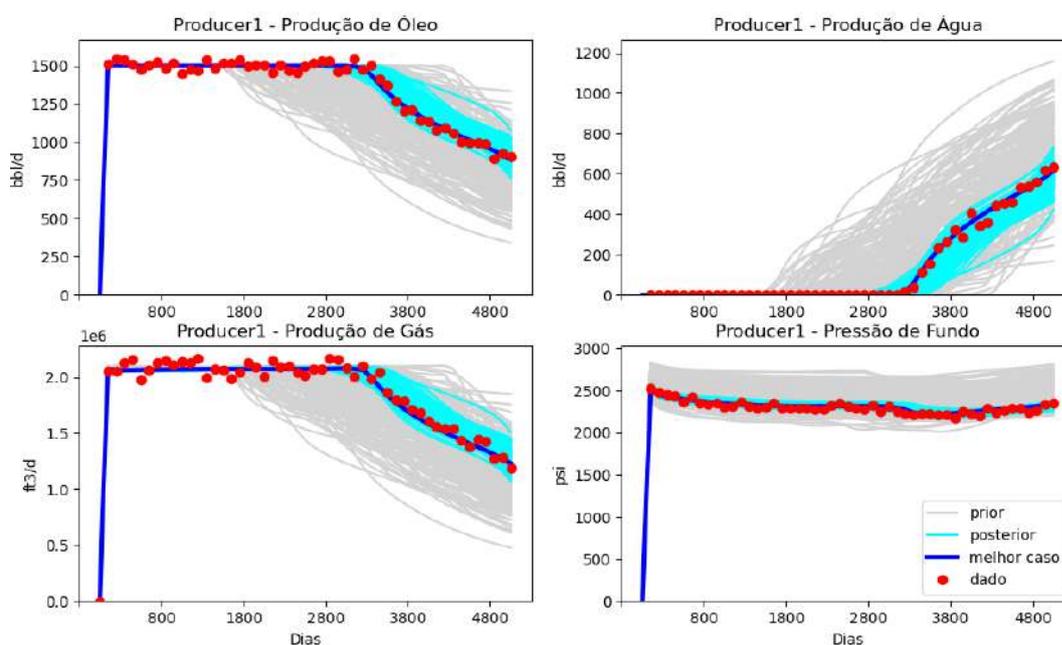


Figura 5.27: Ajuste de histórico das produções de óleo, água, gás e da pressão de fundo do poço “*Producer1*” para o caso de estudo 2B.

Portanto, a melhoria do ajuste de histórico de todo o conjunto de modelos é significativa ao final da aplicação do método, podendo também ser verificadas

nas curvas dos demais poços cujos dados foram incorporados, as quais são apresentadas no apêndice E.

5.4.2 Análise dos Modelos

O fato de ter sido preservado neste estudo um modelo como representação do reservatório de referência, cuja resposta simulada correspondeu aos dados de produção para ajuste de histórico, trouxe a oportunidade de também se avaliar a similaridade deste modelo com as realizações *a priori* e *a posteriori*, o que não seria possível se fossem utilizados dados de campos em produção, onde a representação exata do reservatório permaneceria incerta.

Assim, inicialmente foram calculadas as métricas distância L1 (seção 5.2.2) e SSIM (seção 5.2.3), comparando as “imagens” dos modelos de fácies dos conjuntos *a priori* e *a posteriori* com o modelo representativo do reservatório de referência. As figuras 5.28 a 5.31 consolidam os resultados em *boxplots*, sendo possível constatar que o processo de assimilação de dados produziu em geral realizações de fácies que apresentam uma maior similaridade ao reservatório de referência, representado pela redução da distância L1 e o aumento da métrica SSIM do conjunto *a posteriori*, para todos os casos de estudo.

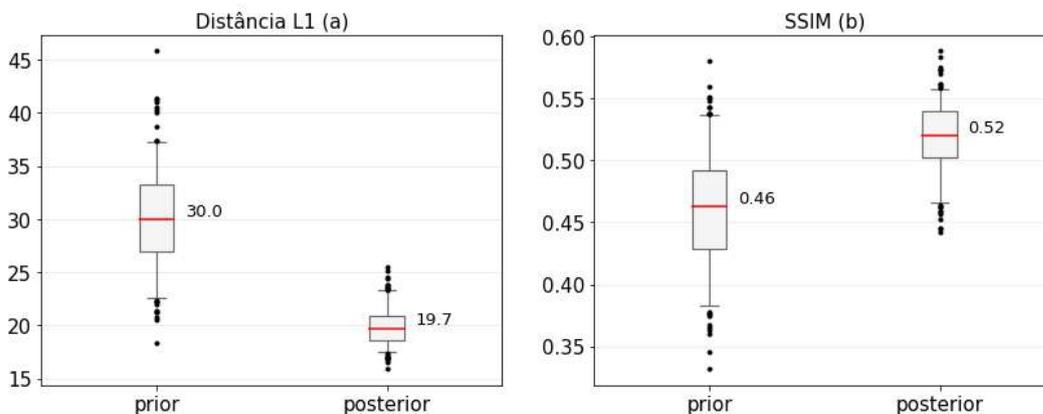


Figura 5.28: Métricas para comparação do modelos de fácies *prior* e *posterior* com o reservatório de referência do caso de estudo 1A: (a) Distância L1; (b) SSIM.

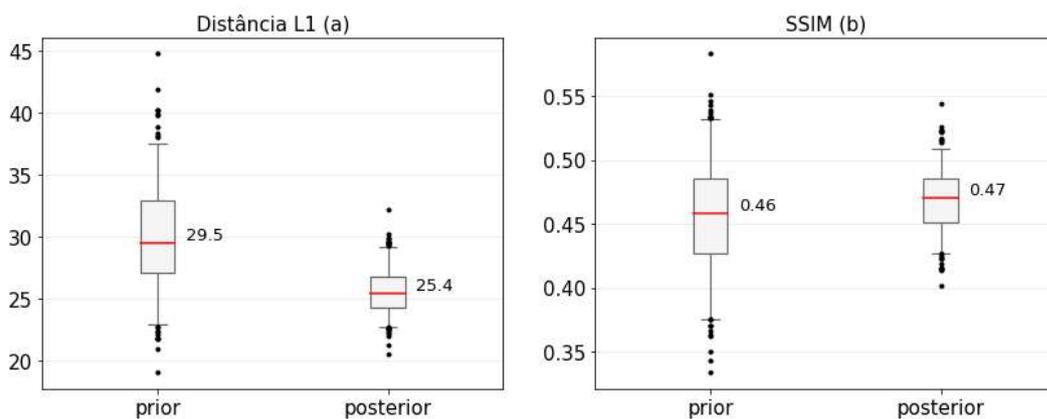


Figura 5.29: Métricas para comparação do modelos de fácies *prior* e *posterior* com o reservatório de referência do caso de estudo 1B: (a) Distância L1; (b) SSIM.

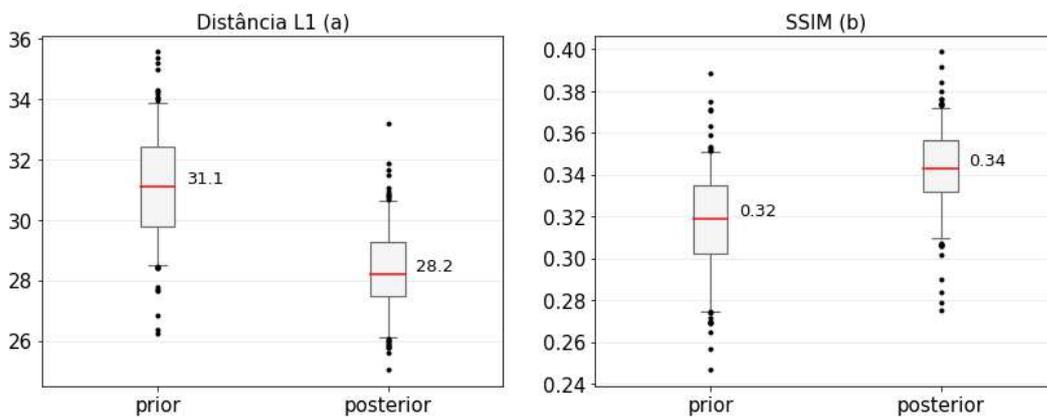


Figura 5.30: Métricas para comparação do modelos de fácies *prior* e *posterior* com o reservatório de referência do caso de estudo 2A: (a) Distância L1; (b) SSIM.

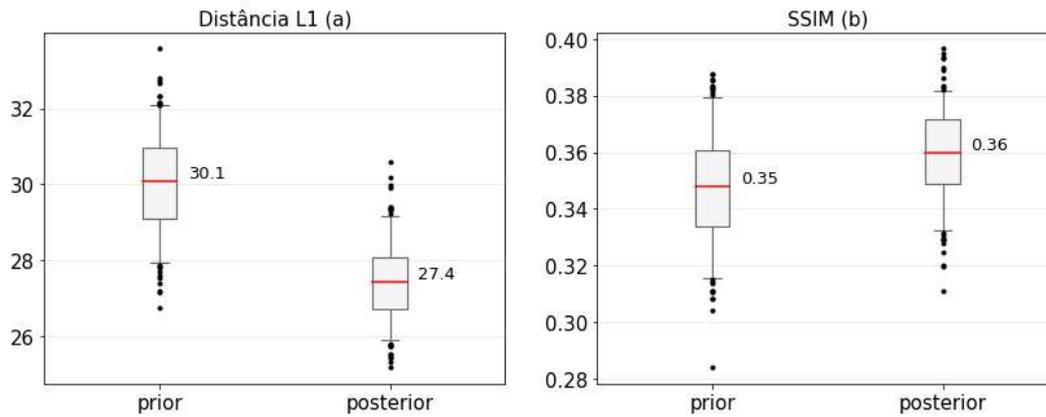


Figura 5.31: Métricas para comparação do modelos de fácies *prior* e *posterior* com o reservatório de referência do caso de estudo 2B: (a) Distância L1; (b) SSIM.

Outra maneira de quantificar a similaridade dos modelos ajustados com o reservatório de referência é através da construção de matrizes de confusão, discutidas na seção 5.2.4. A observação das figuras 5.32 a 5.35 também sugere que, em geral, houve um aumento do número de células onde a classificação de fácies *a posteriori* foi a mesma do reservatório de referência (representada pelo aumento dos valores da diagonal principal), além da redução das divergências entre fácies 1 e 3, para todos os casos de estudo. Em alguns casos, houve um aumento dos erros de classificação envolvendo as fácies 2, como no caso de estudo 1B, mas este pode ser considerado um efeito menos importante, devido a esta representar transição entre as fácies 1 e 3.

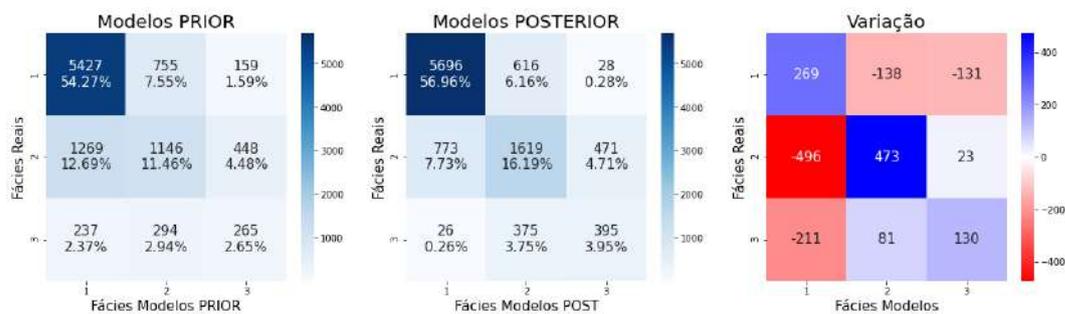


Figura 5.32: Matriz de confusão do caso de estudo 1A.

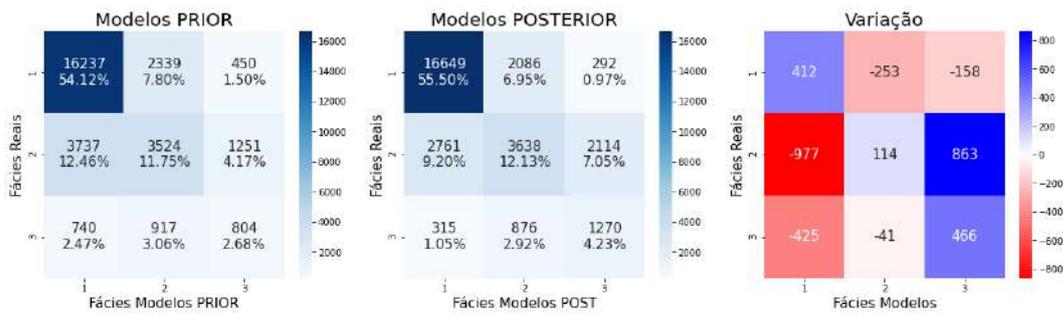


Figura 5.33: Matriz de confusão do caso de estudo 1B.

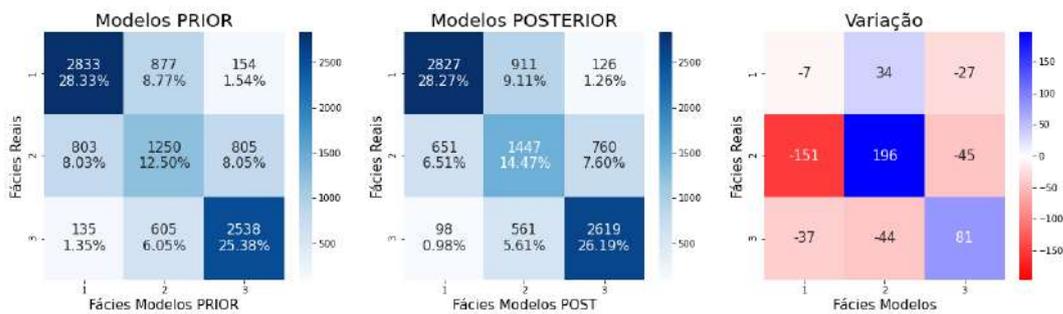


Figura 5.34: Matriz de confusão do caso de estudo 2A.

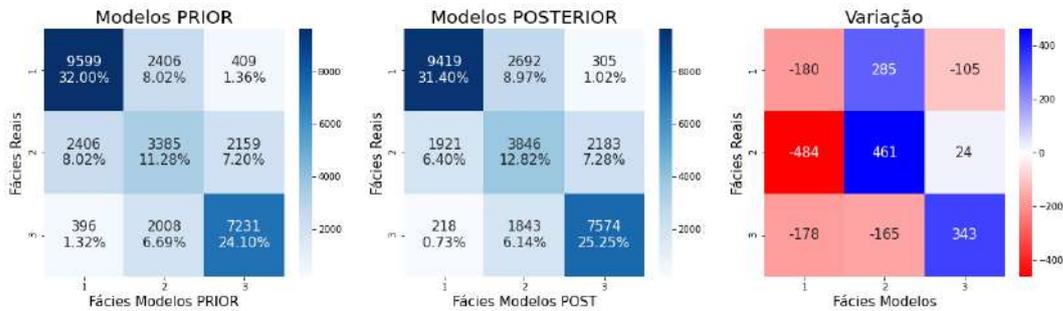


Figura 5.35: Matriz de confusão do caso de estudo 2B.

Após a análise quantitativa da similaridade dos modelos é importante avaliar visualmente o impacto da assimilação dos dados nas características do reservatório. Assim, serão apresentados os mapas das fácies e propriedades petrofísicas (porosidade, permeabilidades), além dos estados dinâmicos dos modelos ao final do período simulado, representados pela pressão e pela saturações de água e de gás no reservatório, sempre comparando as realizações *a priori* e *a posteriori* (dos três modelos que apresentaram o melhor ajuste dos dados históricos) com a representação do reservatório de referência. A discussão destes resultados será realizada, para cada um dos casos de estudo, nas seções 5.4.2.1 a 5.4.2.4.

5.4.2.1

Caso de Estudo 1A

O cenário geológico de caso de estudo 1A representa um grande desafio para o ajuste, uma vez que seu comportamento errático de presença/ausência dos canais faz com que as propriedades se afastem de uma representação gaussiana.

Nesta conjuntura, a figura 5.36 mostra o reservatório de referência (*ground truth*) a esquerda, com os três modelos *a priori* nos quadrantes superiores e seus respectivos *a posteriori* nos inferiores. Nos modelos *a priori*, pode ser observado que há várias descontinuidades (representadas pelas fácies em verde) nos dois canais leste-oeste presentes no modelo de referência. Esse efeito foi corrigido após a incorporação dos dados históricos, com os modelos *a posteriori* conseguindo representar estas continuidades, ao menos através das fácies intermediárias (em amarelo).

O mesmo comportamento foi observado nas propriedades petrofísicas (figuras 5.37 a 5.39), indicando que as modificações realizadas pelo método ES-MDA nestes atributos conseguiram ser refletidas pela rede I2I na tradução para a classificação das fácies, o que está aderente aos propósitos deste estudo.

Outro resultado interessante pode ser inferido dos estados dinâmicos dos modelos. Observando o comportamento da saturação de água ao final da simulação (figura 5.40), conclui-se que a frente de avanço de água a partir do aquífero foi muito bem representada nos modelos, sendo um aspecto em que a fidelidade ao reservatório de referência tem grande importância, principalmente para a perfuração de poços complementares no reservatório. A mesma aderência pode ser observada no comportamento de pressão (figura 5.42), onde a depleção espacial está melhor representada nos modelos *a posteriori* o que também impacta na saturação de gás (figura 5.41), que nos modelos *a priori* indicavam a presença de uma capa de gás secundária significativa a sudoeste do reservatório, a qual não está presente no modelo de referência nem nos modelos cujos dados históricos foram assimilados.

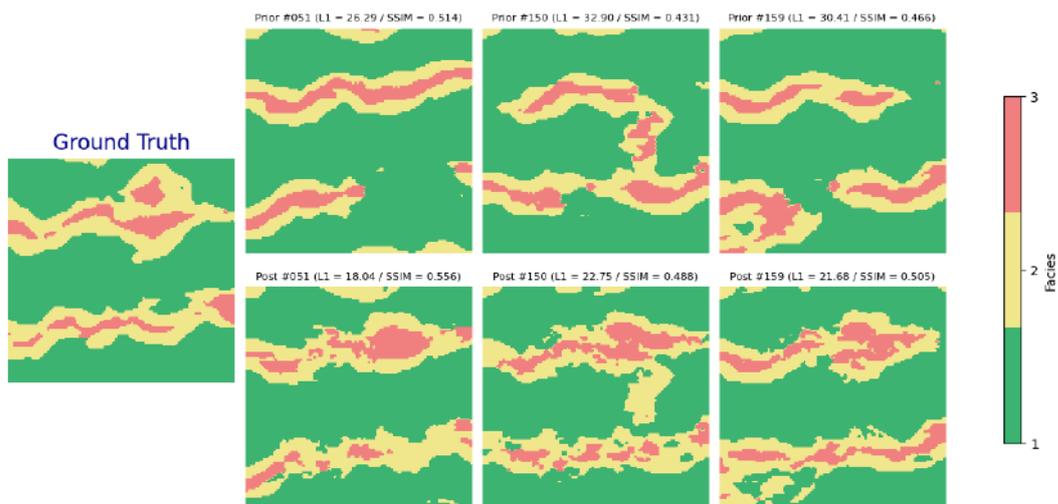


Figura 5.36: Mapas de fácies do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

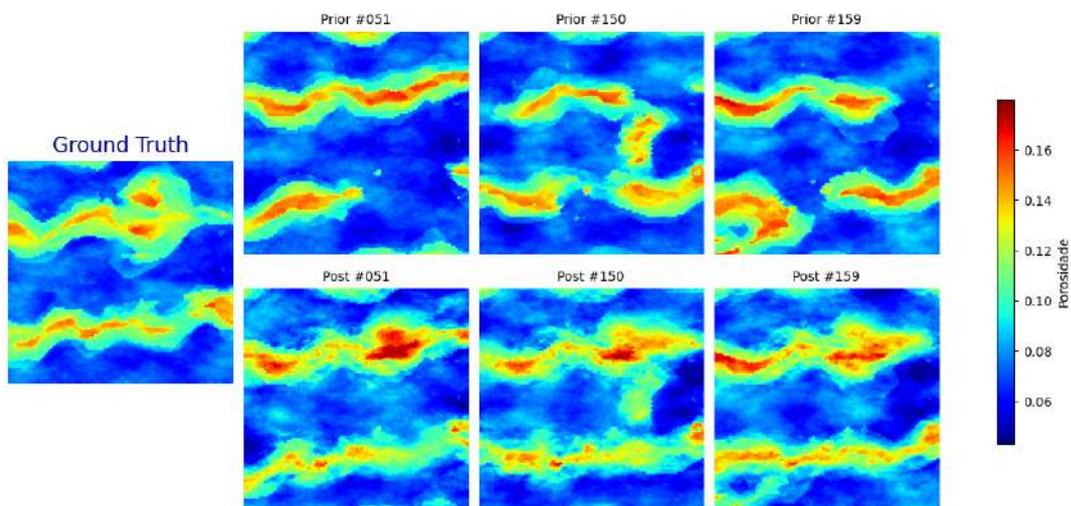


Figura 5.37: Mapas de porosidade do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

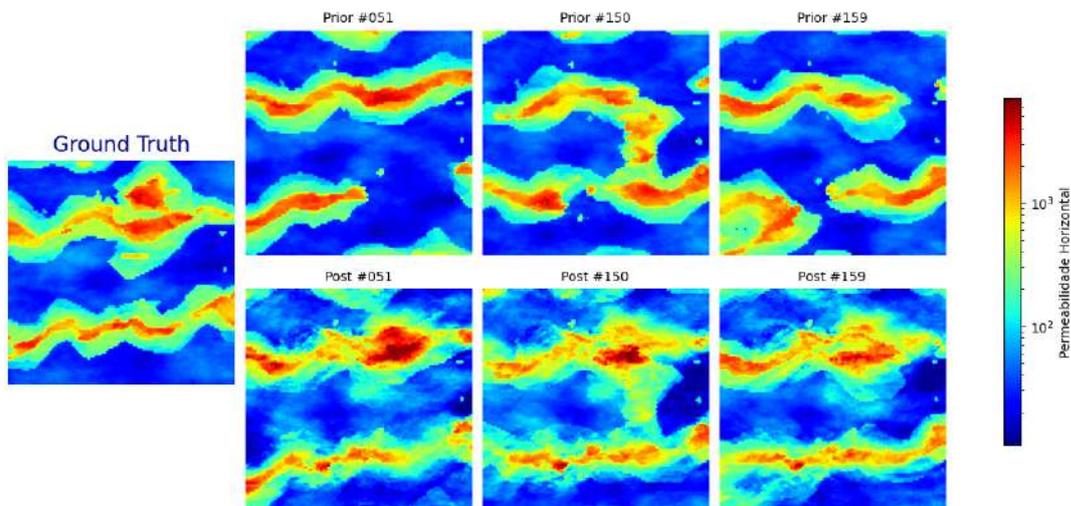


Figura 5.38: Mapas de permeabilidade horizontal do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

PUC-Rio - Certificação Digital N° 2020961/CA

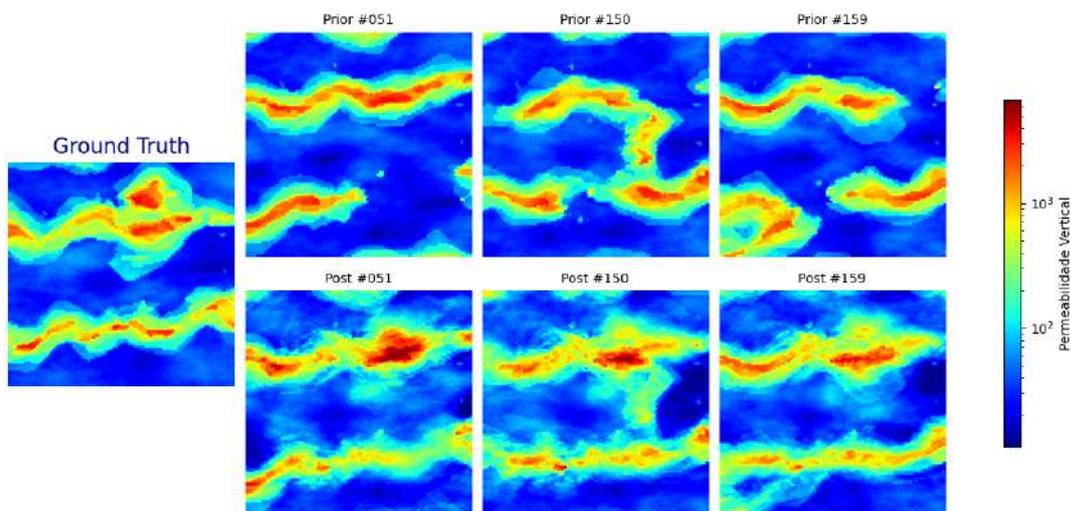


Figura 5.39: Mapas de permeabilidade vertical do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

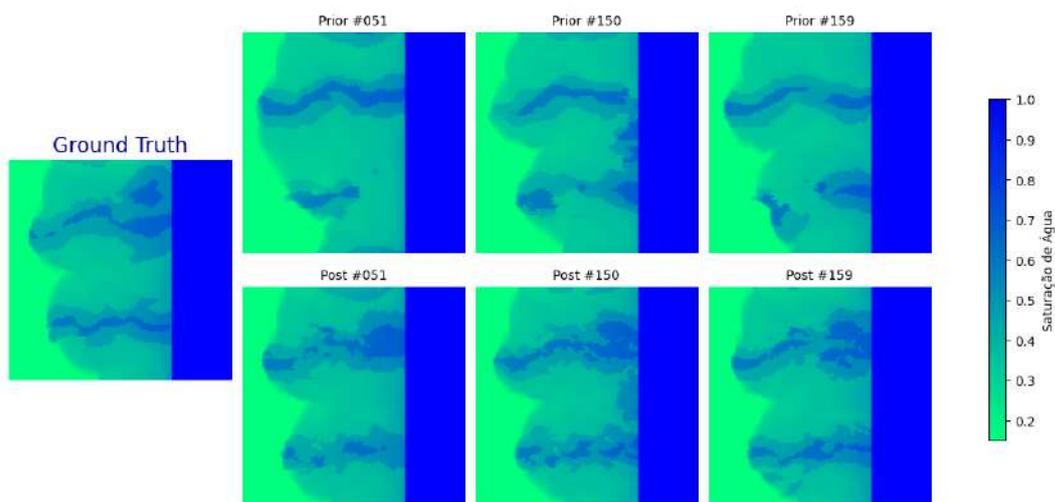


Figura 5.40: Mapas de saturação de água do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

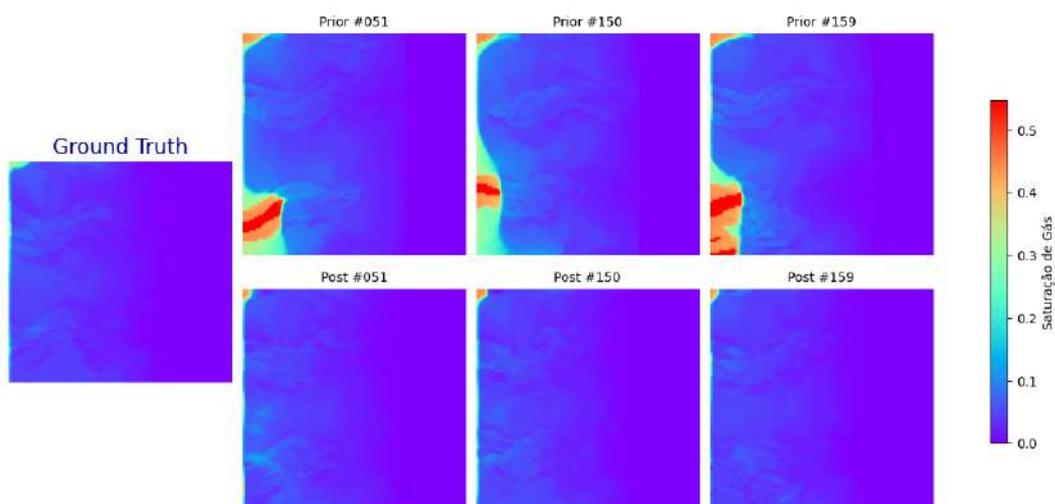


Figura 5.41: Mapas de saturação de gás do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

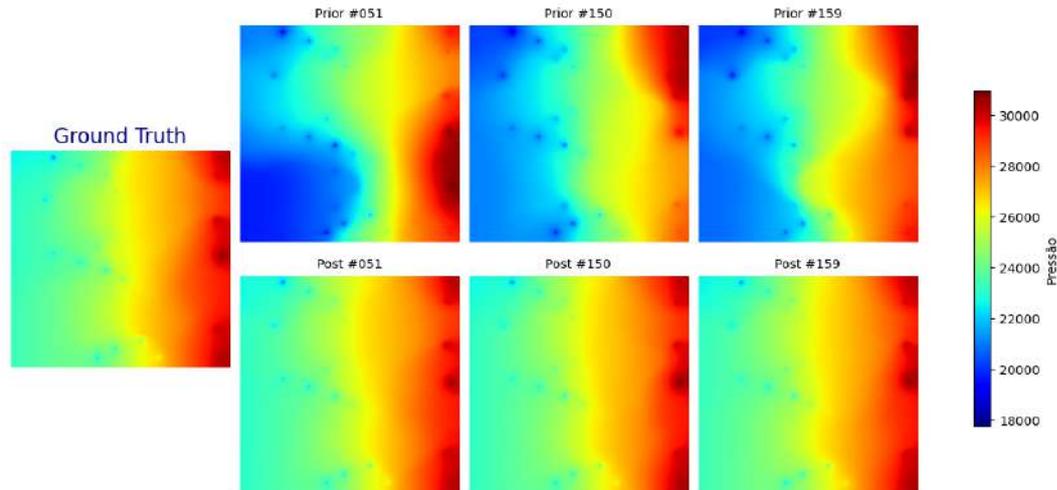


Figura 5.42: Mapas de pressão do caso de estudo 1A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

5.4.2.2

Caso de Estudo 1B

O caso de estudo de canais com 3 camadas (1B) apresentou um comportamento semelhante ao caso que sofreu *upscaling* (1A), com a continuidade dos canais melhor representada, principalmente nas camadas inferiores (5.45), onde há descontinuidades severas nos modelos *a priori*.

Entretanto, neste caso verificou-se feições mais “granuladas” das fácies de alta energia (classe 3), também representados por valores altos nas propriedades petrofísicas (figuras 5.46 a 5.51). Neste caso os efeitos não gaussianos discutidos na seção anterior podem ter ainda maior influência, pois o *upscaling* realizado no caso 1A pode ter operado como um fator atenuador, ao efetuar médias entre três camadas.

Outro fator que poderia ter contribuído para este efeito, foi a opção por não modificar a topologia da rede, mantendo-se os três canais de entrada e definindo-se uma transformação geral para comprimir as duas propriedades em uma ($\log(k)/\phi$), perdendo-se a oportunidade de deixar a rede aprender, durante o treinamento, a relação entre as propriedades que otimiza o desempenho da tarefa de tradução.

Mesmo assim, a representação dos estados dinâmicos continuou a apresentar uma melhoria notável, com os modelos *a posteriori* representando os

formatos das frentes de avanço de água em cada camada (figuras 5.52 a 5.54), além da depleção (figuras 5.58 a 5.60) e da presença de gás (figuras 5.55 a 5.57) no reservatório.

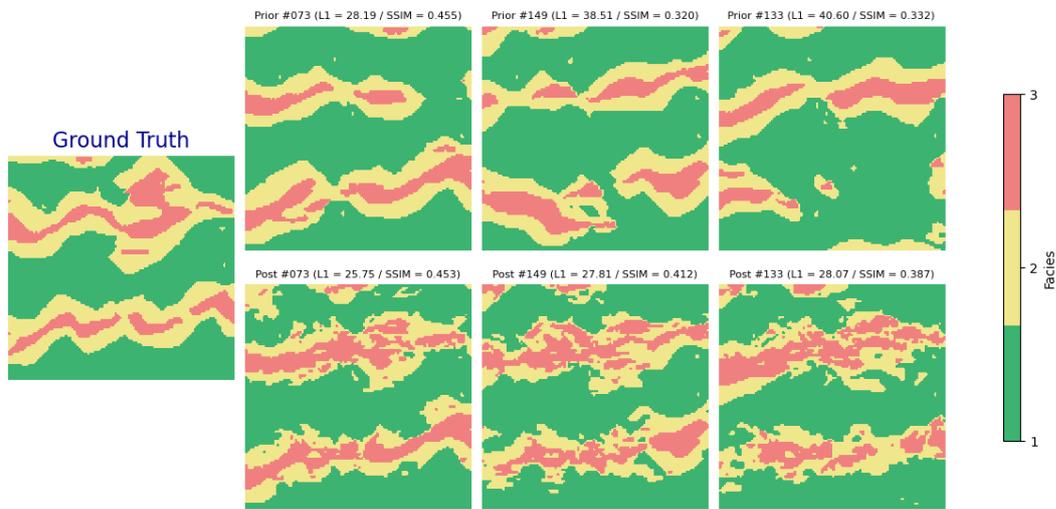


Figura 5.43: Mapas de fácies da camada 01 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

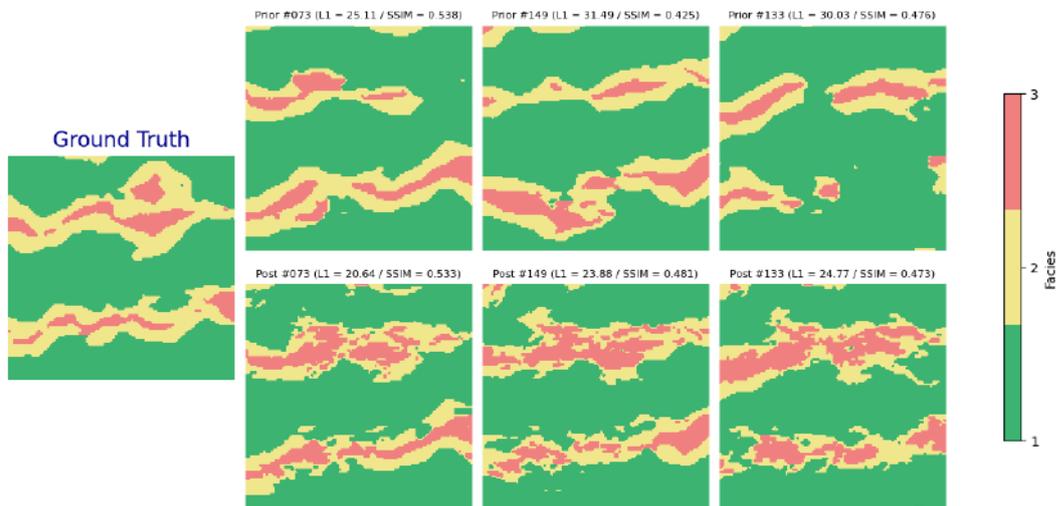


Figura 5.44: Mapas de fácies da camada 02 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

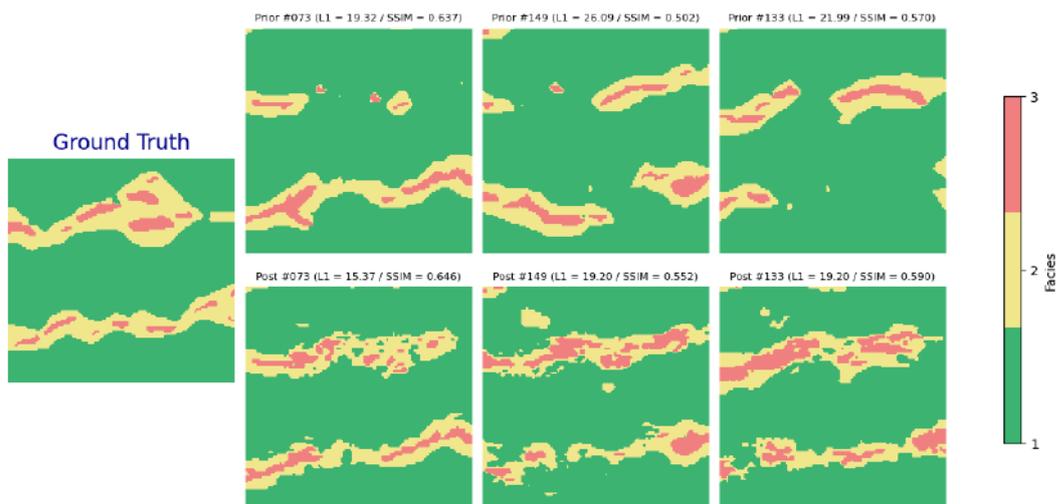


Figura 5.45: Mapas de fácies da camada 03 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

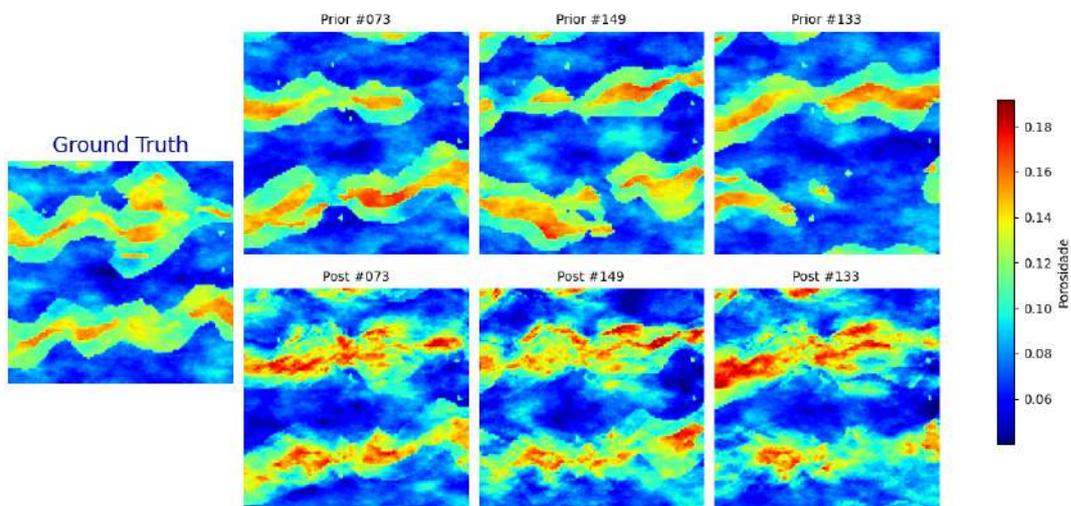


Figura 5.46: Mapas de porosidade da camada 01 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

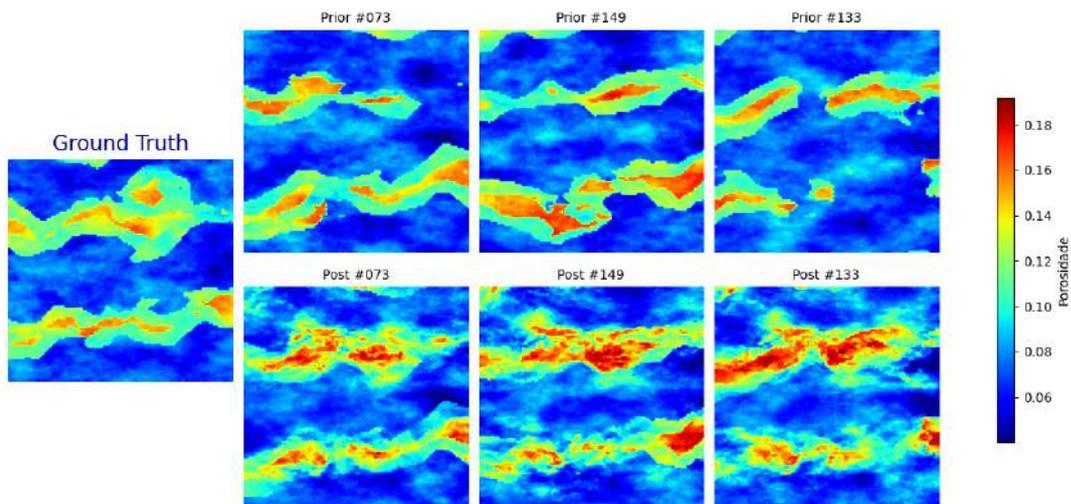


Figura 5.47: Mapas de porosidade da camada 02 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

PUC-Rio - Certificação Digital N° 2020961/CA

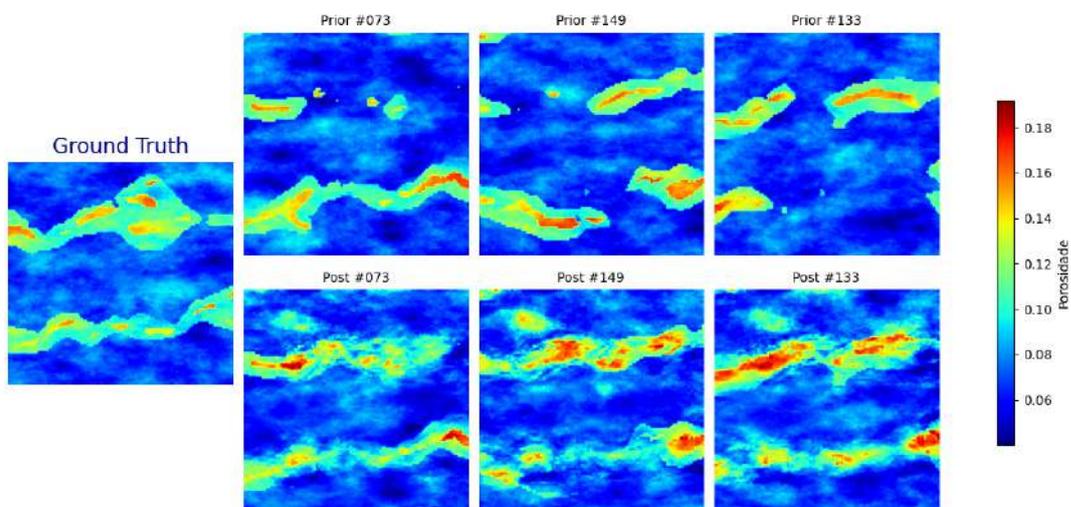


Figura 5.48: Mapas de porosidade da camada 03 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

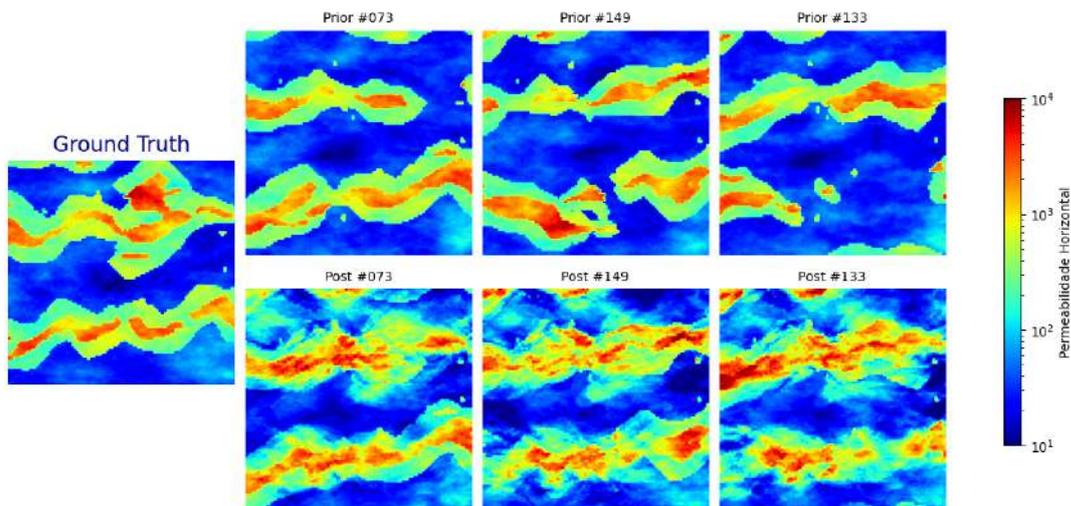


Figura 5.49: Mapas de permeabilidade horizontal da camada 01 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

PUC-Rio - Certificação Digital N° 2020961/CA

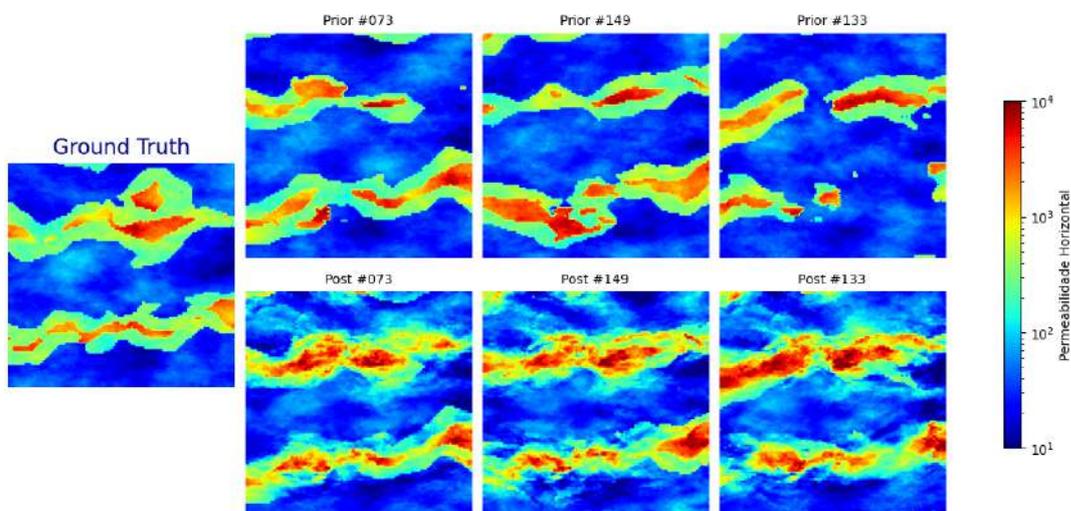


Figura 5.50: Mapas de permeabilidade horizontal da camada 02 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

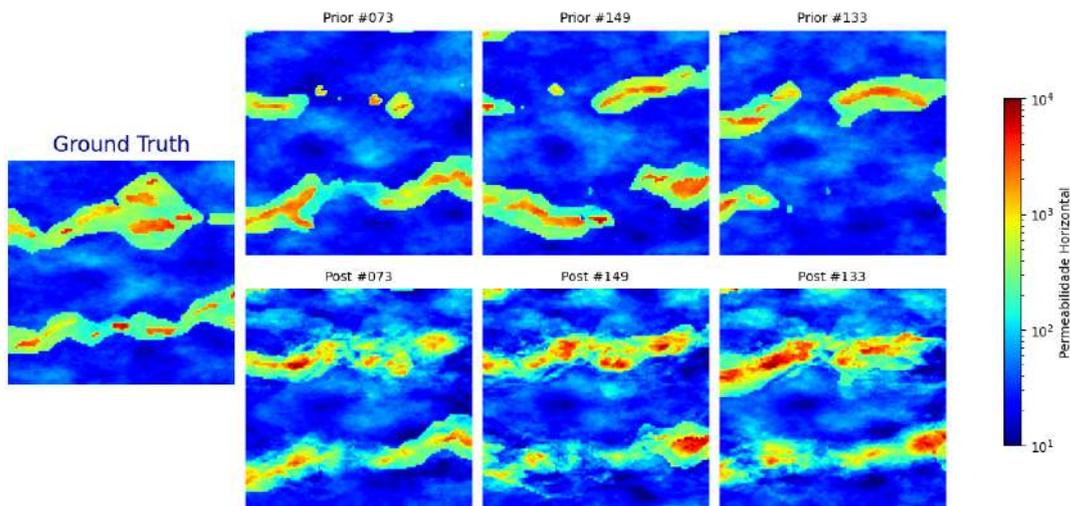


Figura 5.51: Mapas de permeabilidade horizontal da camada 03 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

PUC-Rio - Certificação Digital N° 2020961/CA

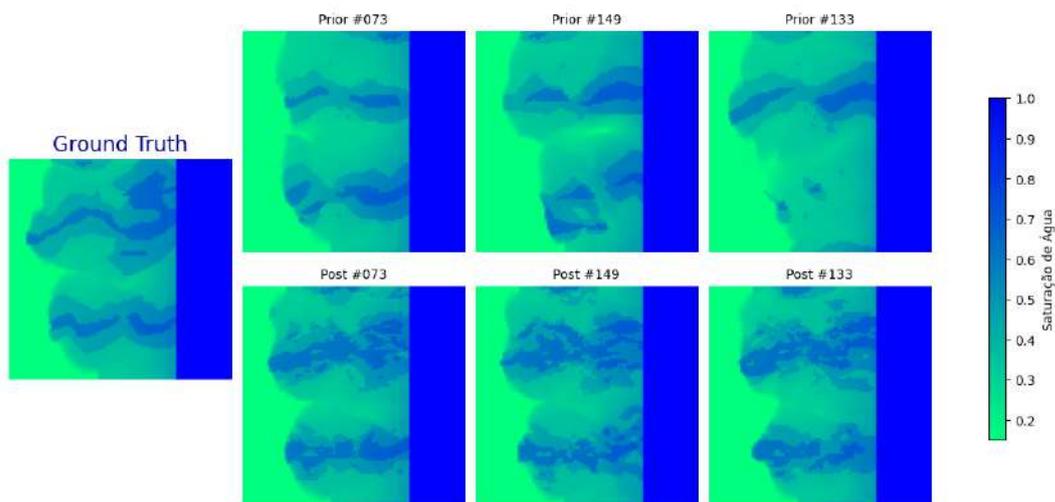


Figura 5.52: Mapas de saturação de água da camada 01 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

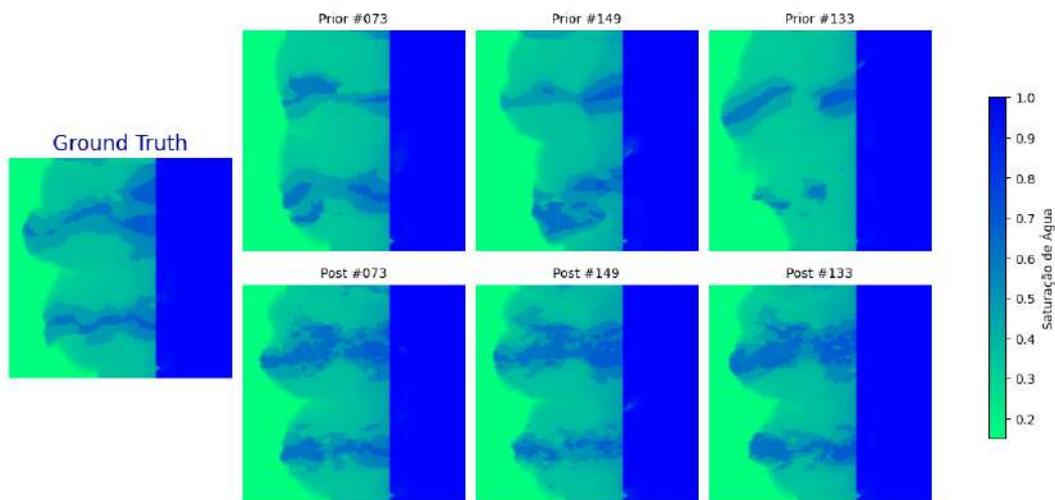


Figura 5.53: Mapas de saturação de água da camada 02 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

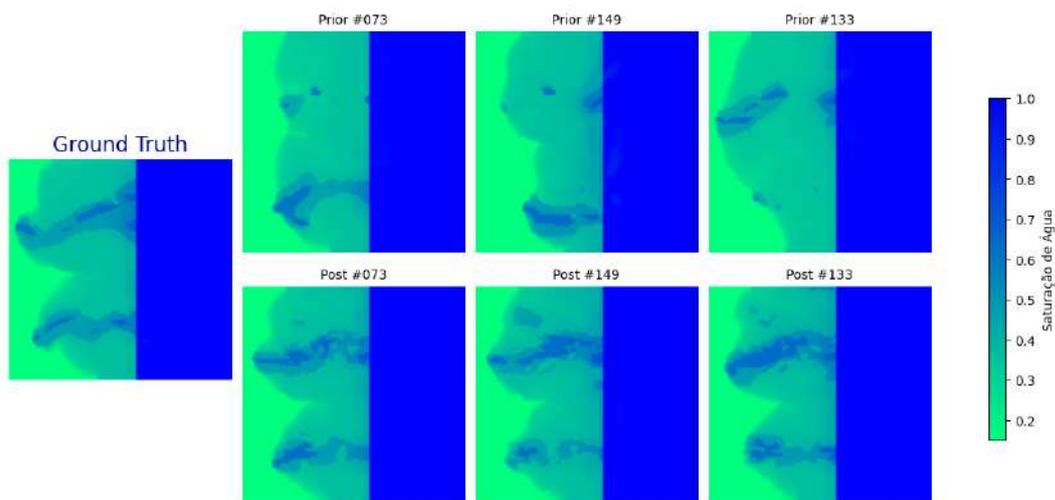


Figura 5.54: Mapas de saturação de água da camada 03 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

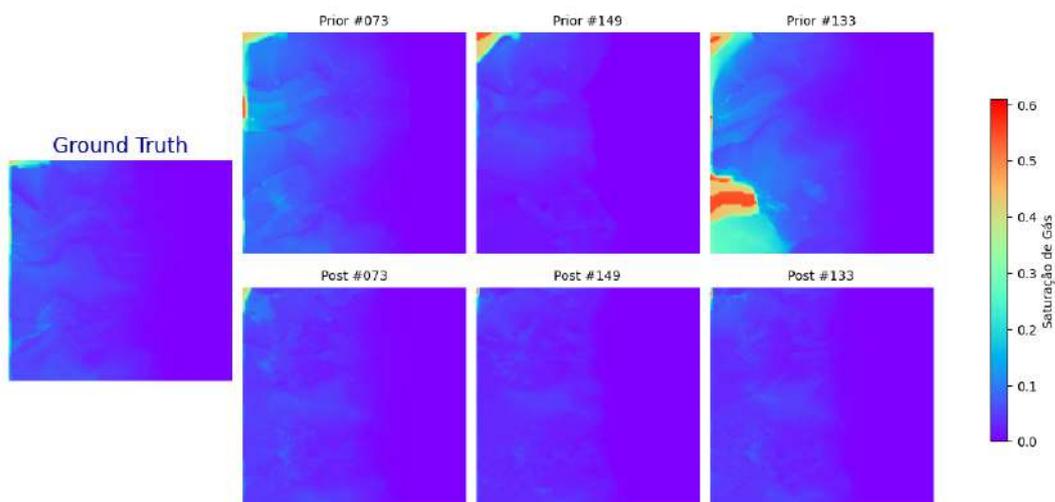


Figura 5.55: Mapas de saturação de gás da camada 01 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

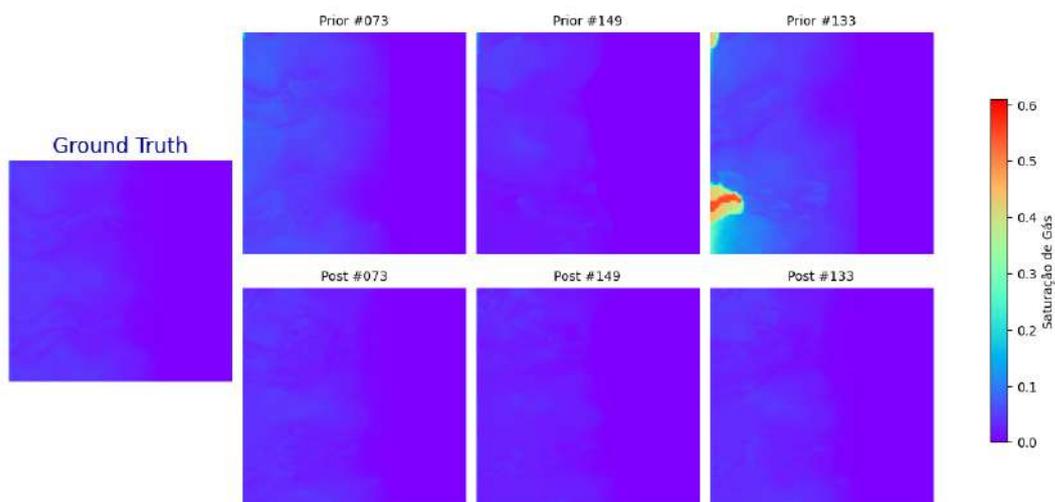


Figura 5.56: Mapas de saturação de gás da camada 02 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

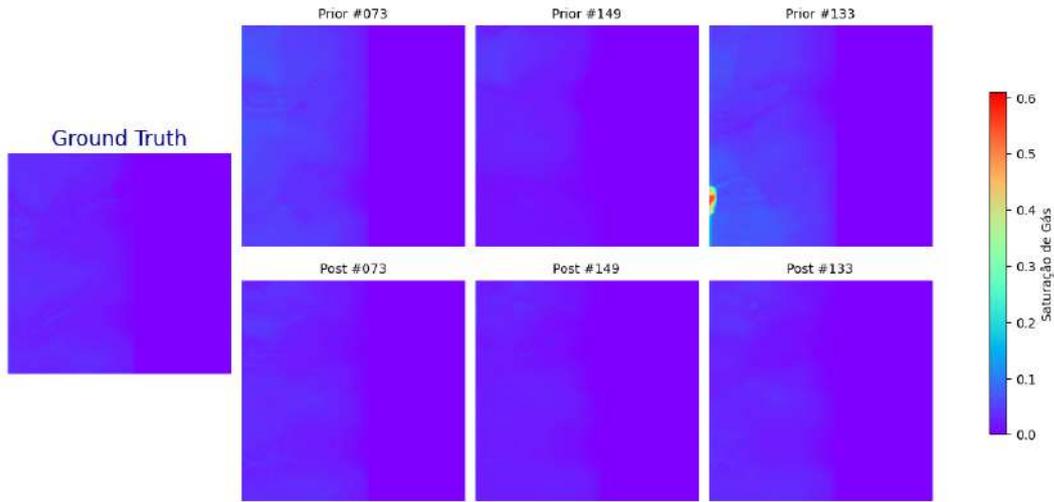


Figura 5.57: Mapas de saturação de gás da camada 03 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

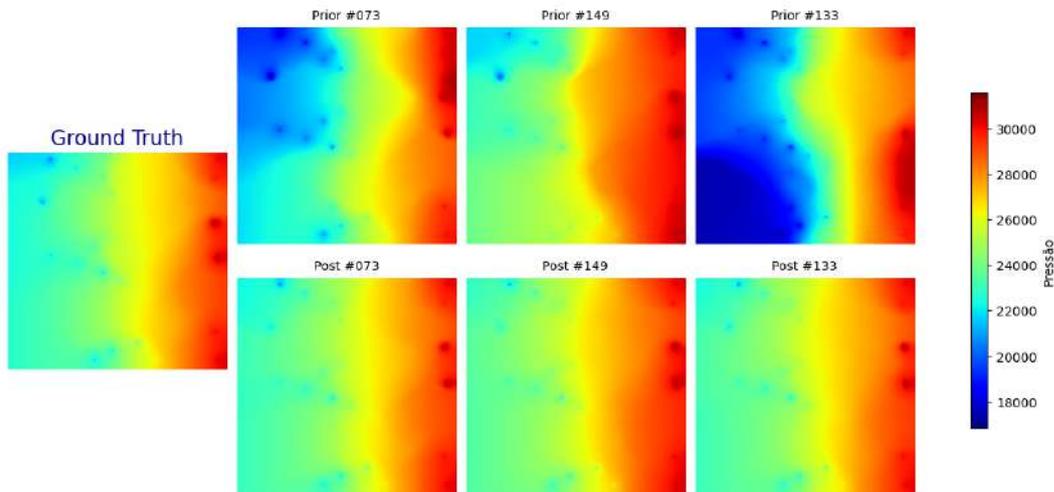


Figura 5.58: Mapas de pressão da camada 01 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

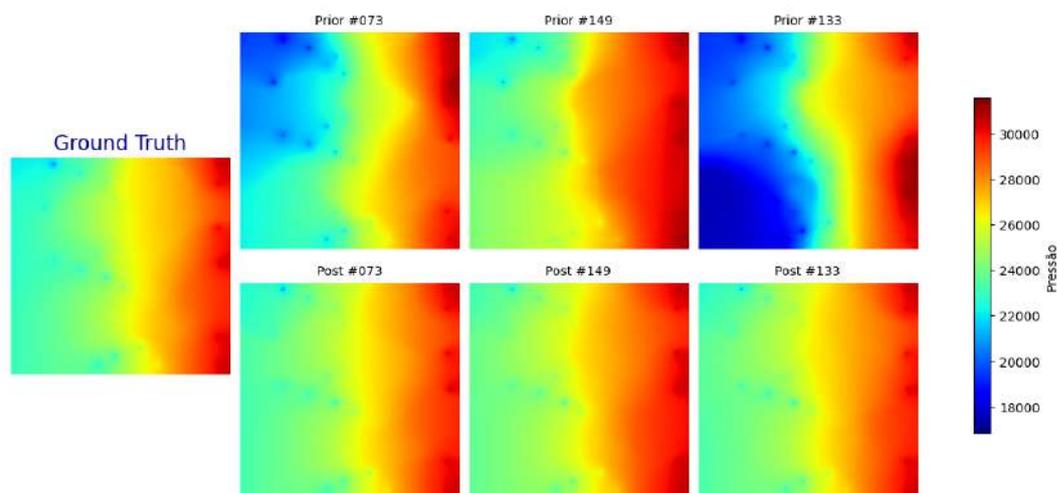


Figura 5.59: Mapas de pressão da camada 02 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

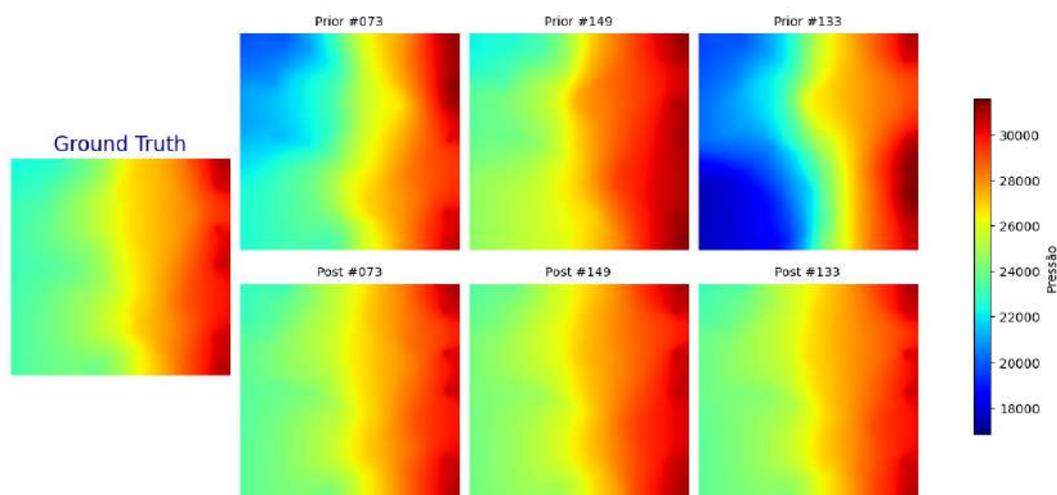


Figura 5.60: Mapas de pressão da camada 03 do caso de estudo 1B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

5.4.2.3

Caso de Estudo 2A

O cenário geológico de lobos deltaicos do caso de estudo 2A pode ser considerado menos desafiador do que o caso 1A, do ponto de vista do ajuste pelo método ES-MDA. Isso pode ser constatado ao compararmos a distribuição característica dos parâmetros a serem ajustados em ambos os cenários.

Como exemplo, a figura 5.61 mostra os histogramas da porosidade de uma das células ao longo dos 200 modelos *a priori* e *a posteriori* para os casos de estudo 1A e 2A. Percebe-se que o histograma dos modelos *a priori* do caso 1A, em vermelho na figura 5.61a é claramente não gaussiano, apresentando 3 modas, o que é modificado após o ajuste com o histograma se aproximando de uma normal, efeito esperado ao se aplicar o método ES-MDA. Enquanto isso, no caso 2A (figura 5.61b) observa-se que já nos modelos *a priori* o parâmetro possui uma distribuição normal o que, em tese, proporcionaria um melhor desempenho do método de ajuste assistido.

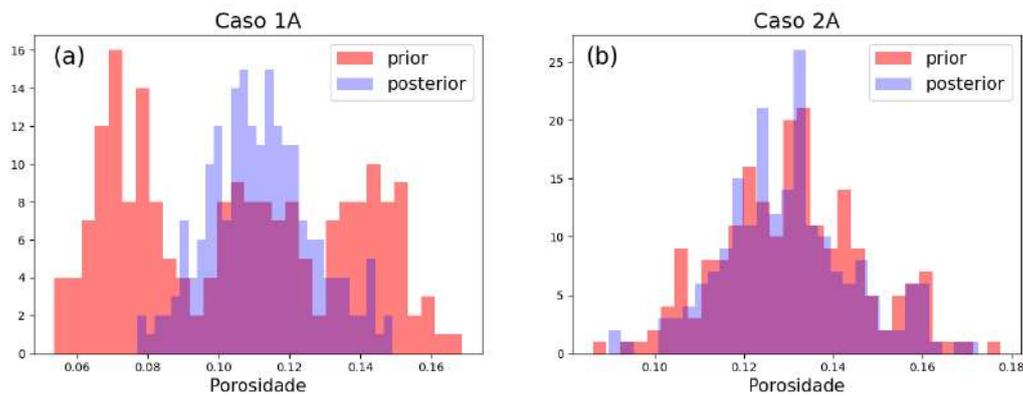


Figura 5.61: Histogramas da porosidade de uma das células ao longo dos 200 modelos *a priori* e *a posteriori*: (a) caso de estudo 1A; (b) caso de estudo 2A.

Portanto, o resultado da assimilação de dados também foi bem sucedido, com os modelos *a posteriori* conseguindo representar algumas feições e artefatos presentes no modelo de fácies de referência (figura 5.62), além de uma melhor representação das propriedades petrofísicas (figuras 5.63 a 5.65). Dadas as características do modelo, com uma maior proporção de fácies de alta e média energias, os efeitos nos estados dinâmicos são mais sutis à primeira vista, sendo mais pronunciadas na saturação de água (figura 5.66).

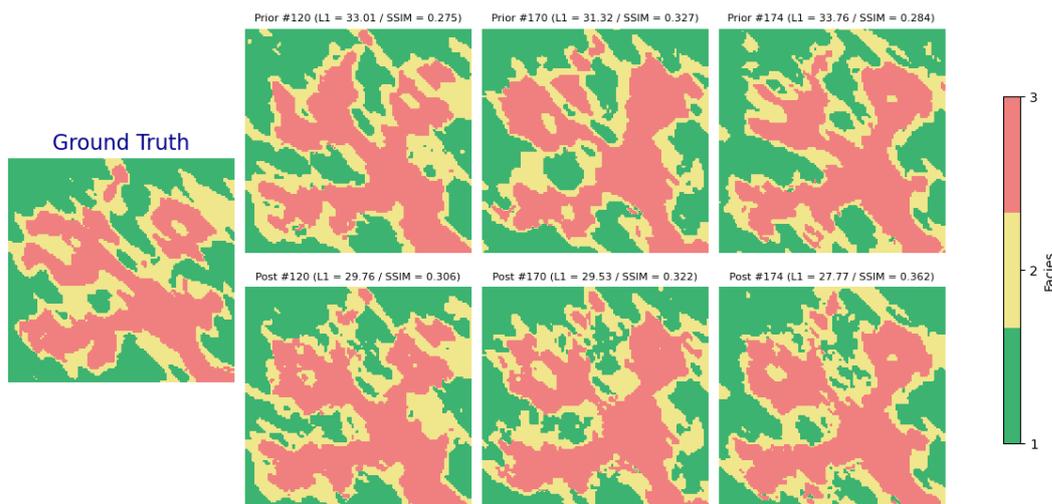


Figura 5.62: Mapas de fácies do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

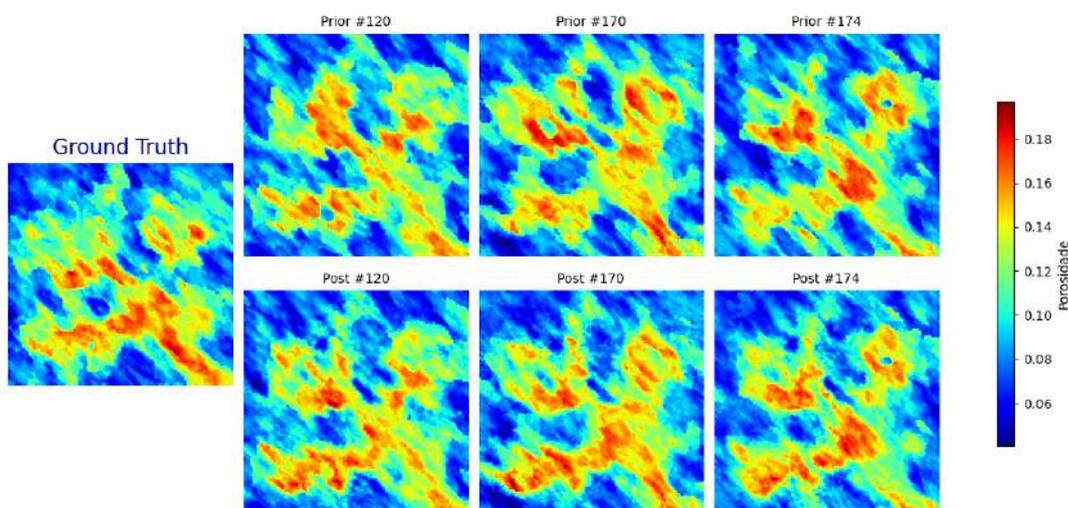


Figura 5.63: Mapas de porosidade do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

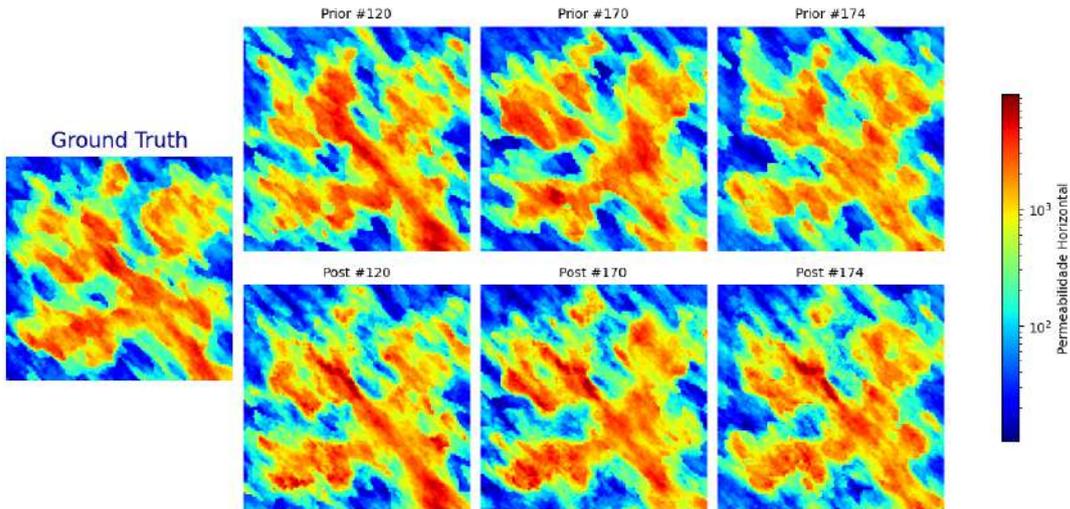


Figura 5.64: Mapas de permeabilidade horizontal do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

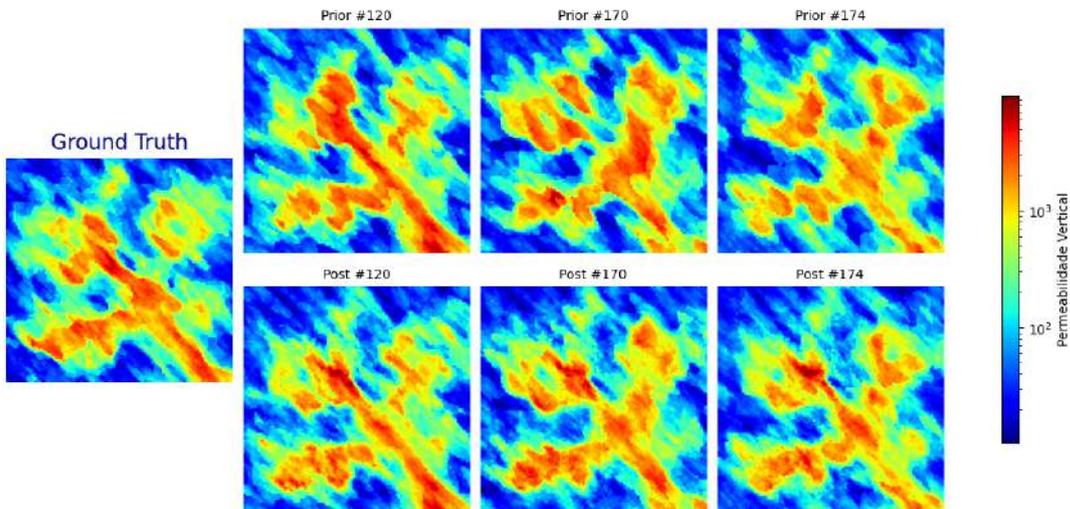


Figura 5.65: Mapas de permeabilidade vertical do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

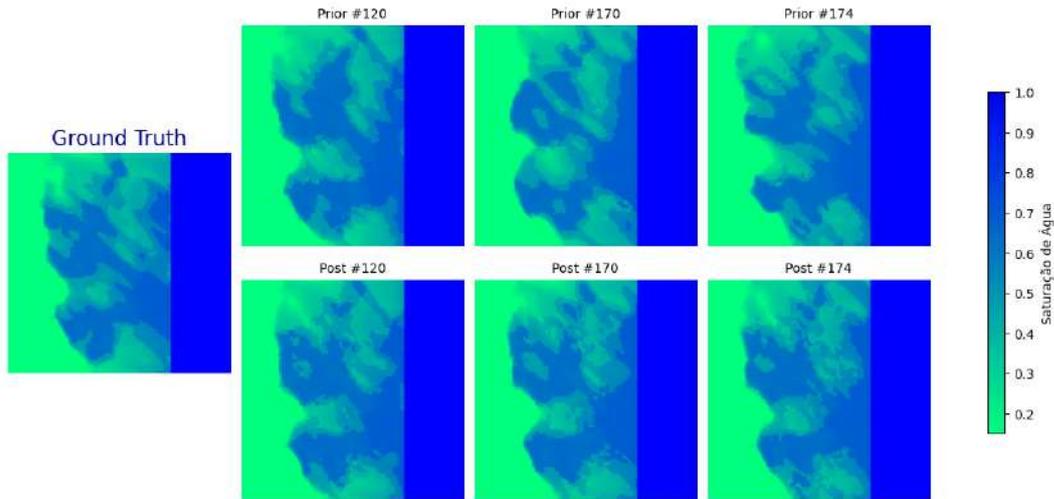


Figura 5.66: Mapas de saturação de água do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

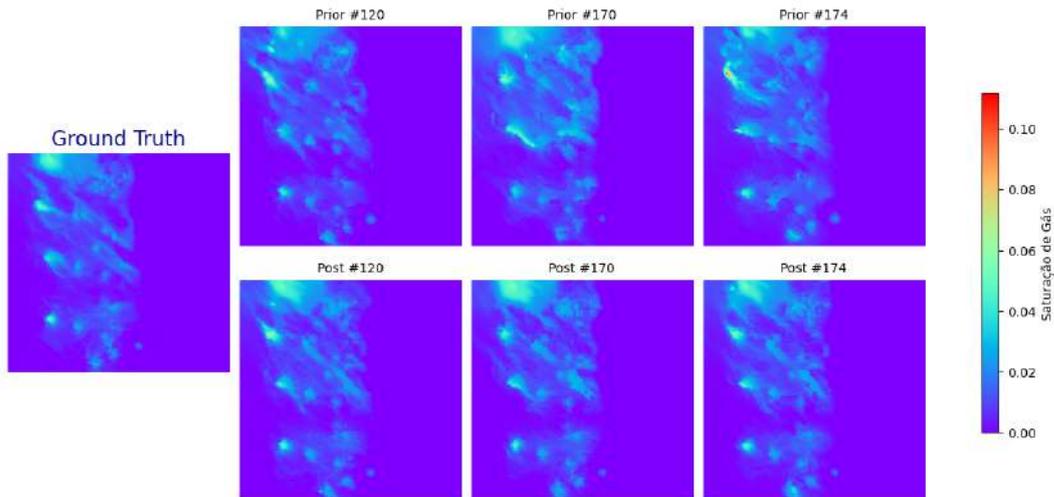


Figura 5.67: Mapas de saturação de gás do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

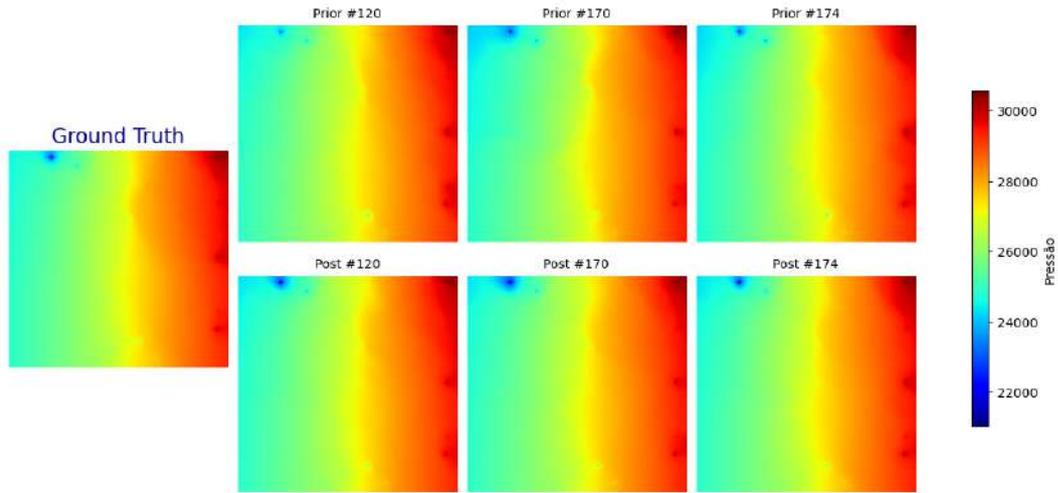


Figura 5.68: Mapas de pressão do caso de estudo 2A comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

5.4.2.4 Caso de Estudo 2B

Para o caso de estudo 2B podem ser feitas as mesmas considerações do caso 2A, reforçando ainda mais a melhoria na representação da saturação de água nas três camadas pelos modelos *a posteriori* (figuras 5.78 a 5.80).

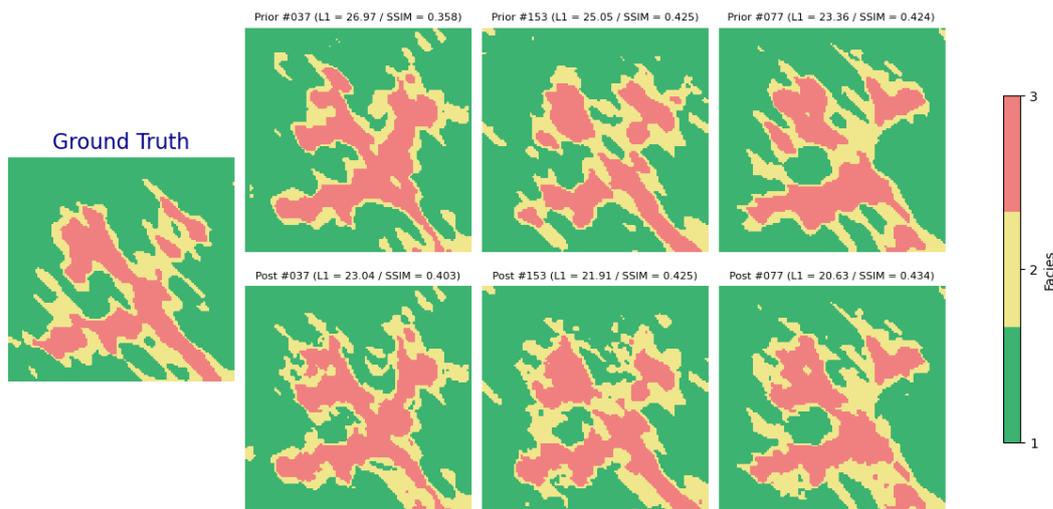


Figura 5.69: Mapas de fácies da camada 01 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

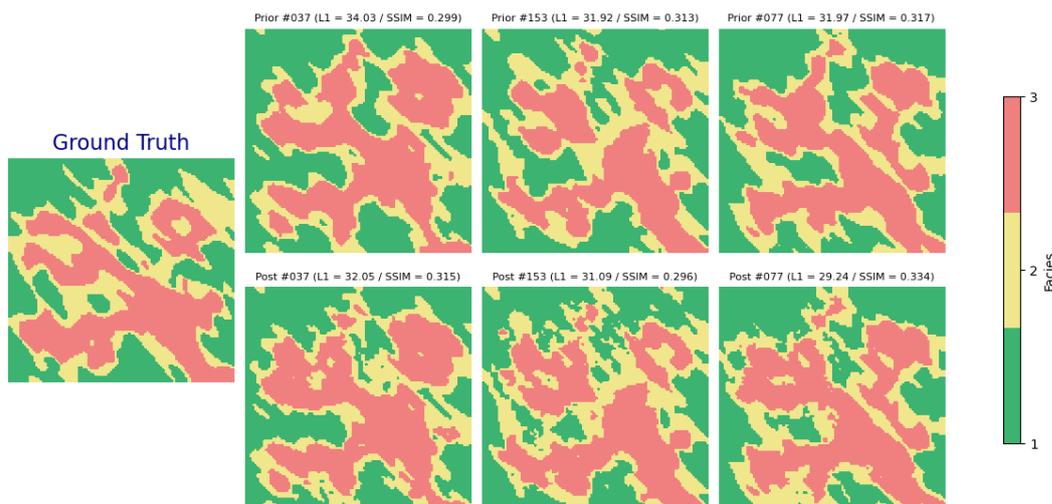


Figura 5.70: Mapas de fácies da camada 02 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

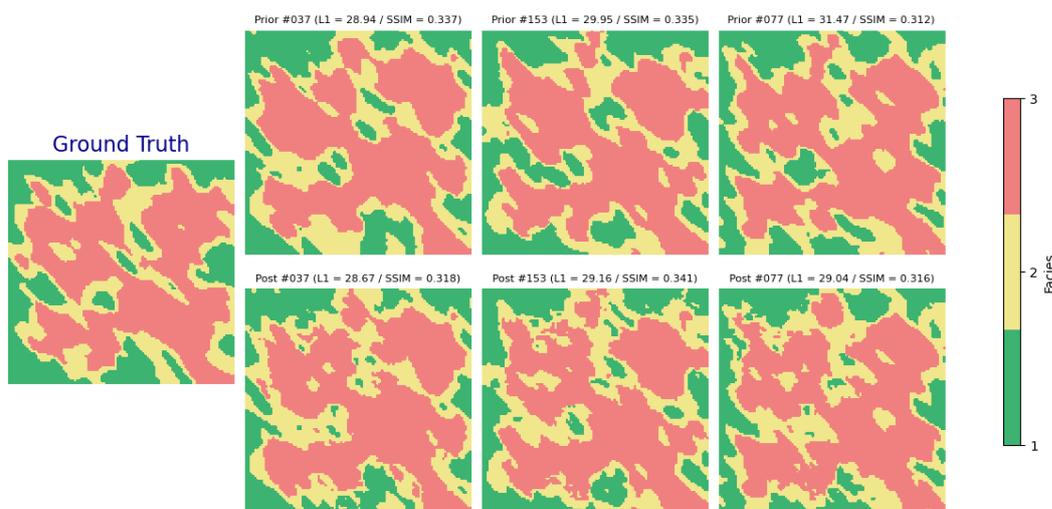


Figura 5.71: Mapas de fácies da camada 03 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

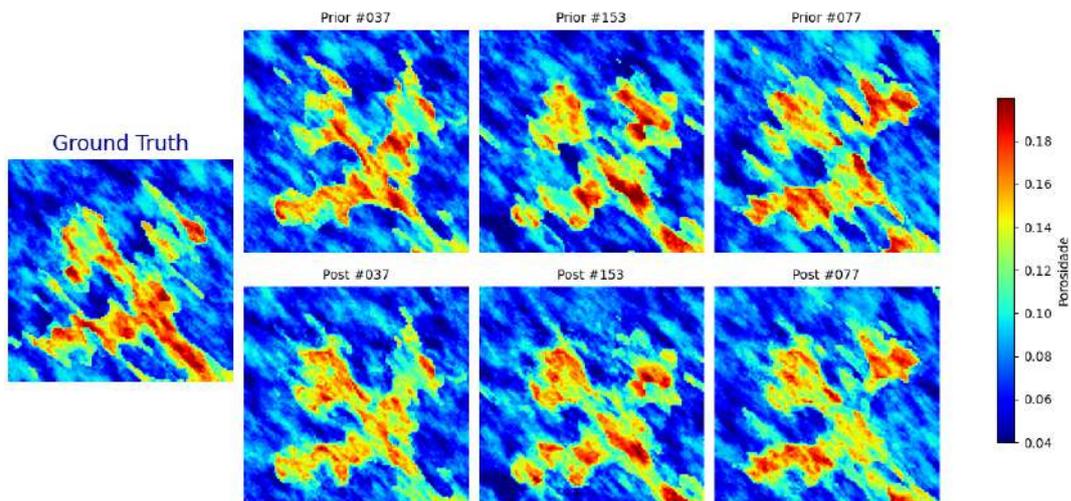


Figura 5.72: Mapas de porosidade da camada 01 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

PUC-Rio - Certificação Digital N° 2020961/CA

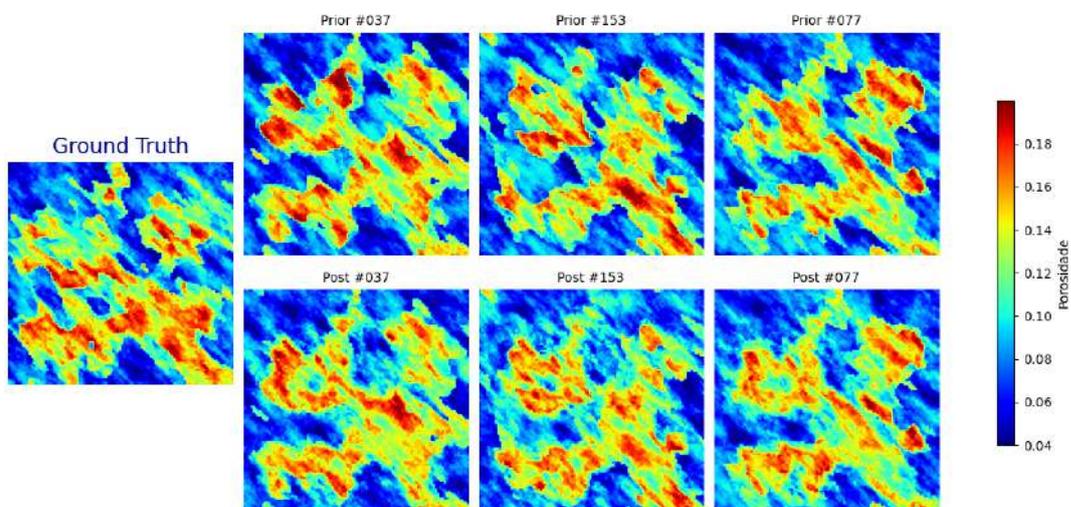


Figura 5.73: Mapas de porosidade da camada 02 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

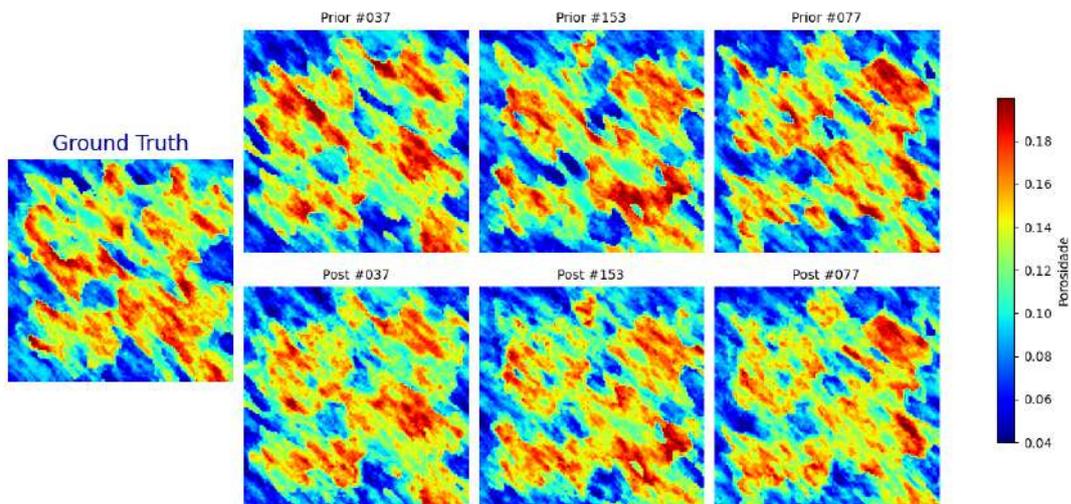


Figura 5.74: Mapas de porosidade da camada 03 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

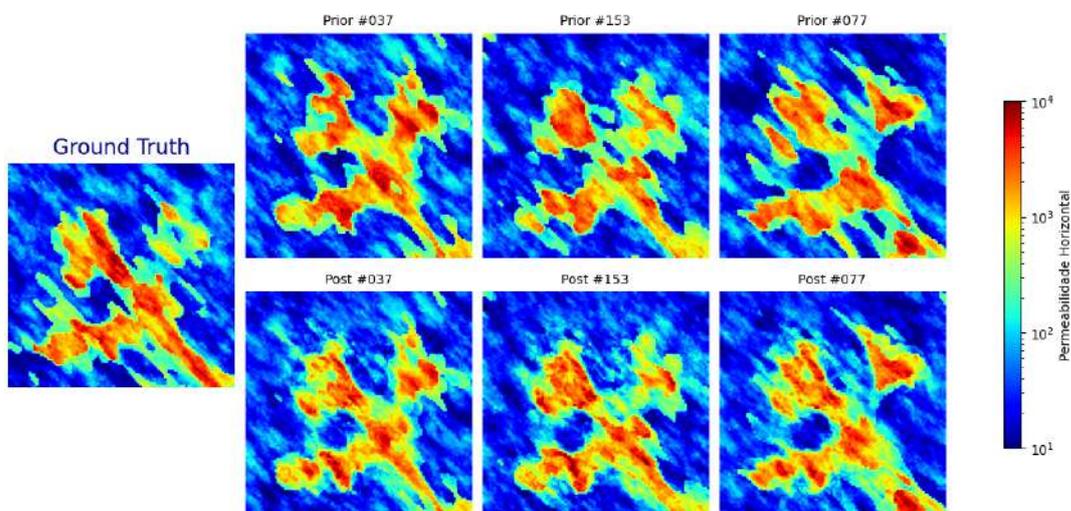


Figura 5.75: Mapas de permeabilidade horizontal da camada 01 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

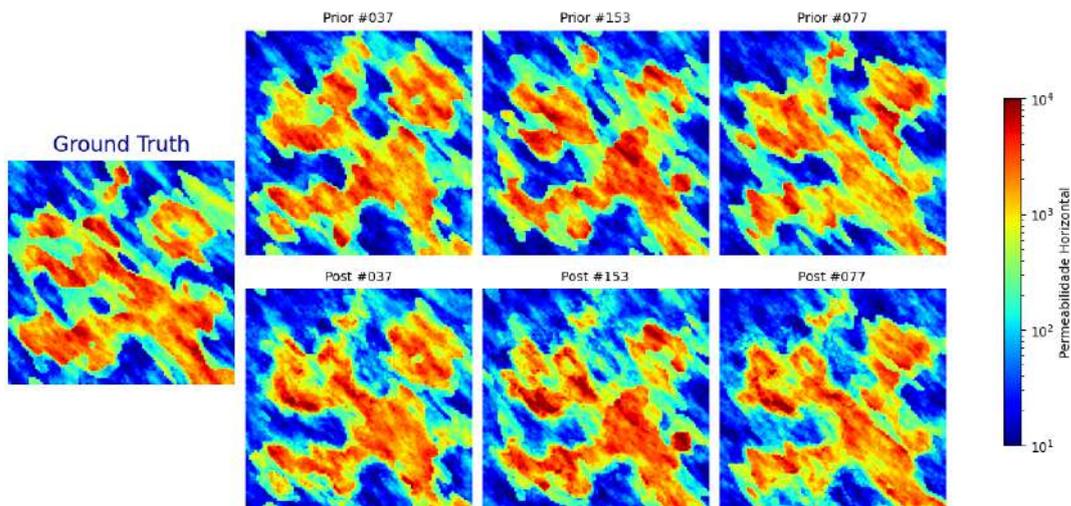


Figura 5.76: Mapas de permeabilidade horizontal da camada 02 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

PUC-Rio - Certificação Digital N° 2020961/CA

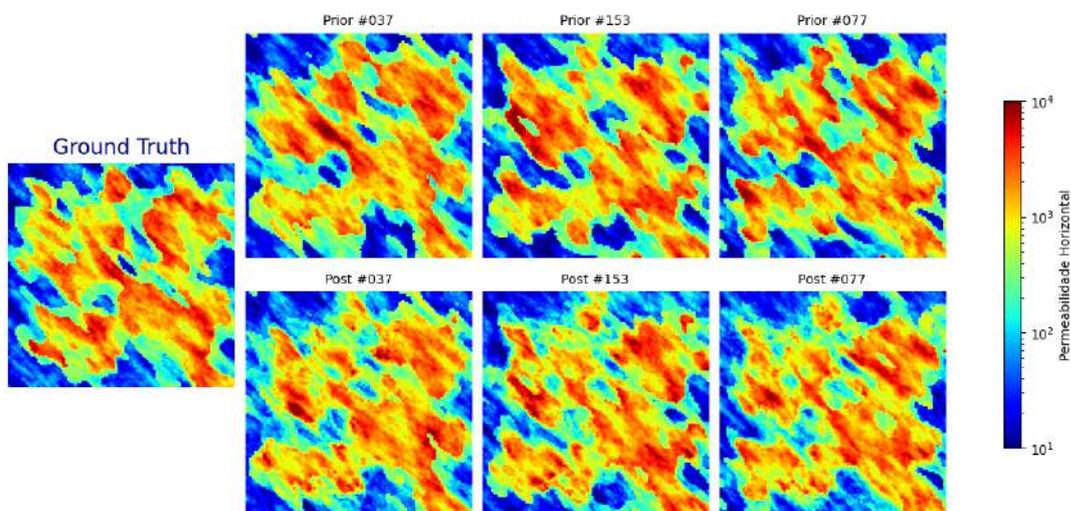


Figura 5.77: Mapas de permeabilidade horizontal da camada 03 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

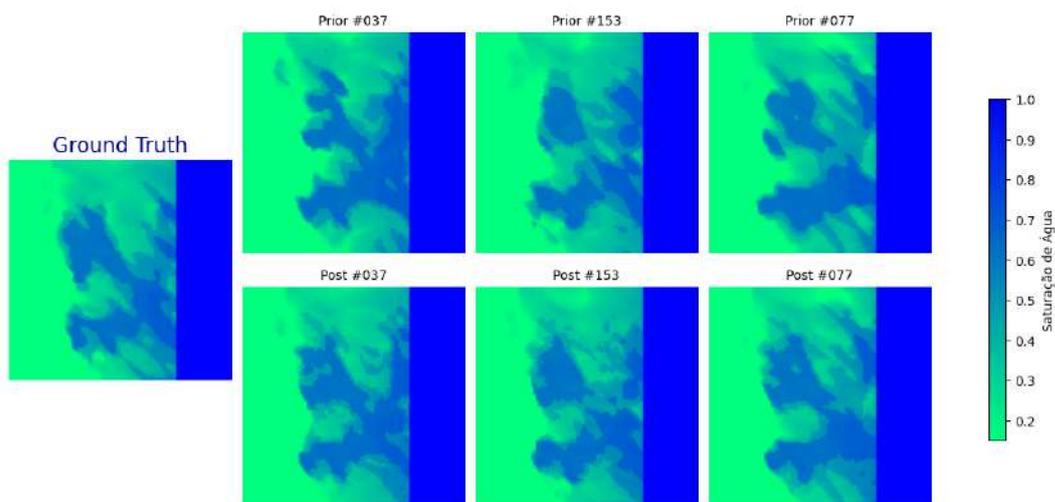


Figura 5.78: Mapas de saturação de água da camada 01 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

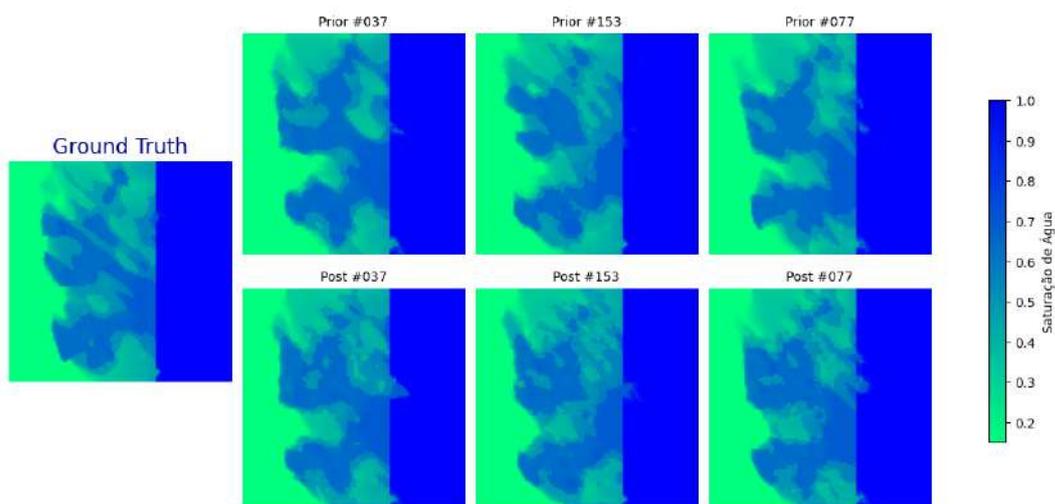


Figura 5.79: Mapas de saturação de água da camada 02 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

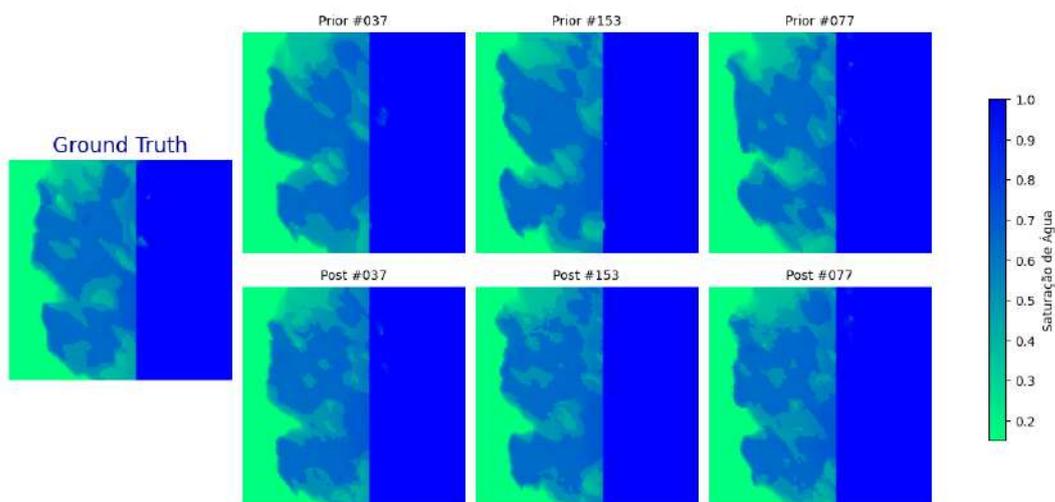


Figura 5.80: Mapas de saturação de água da camada 03 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

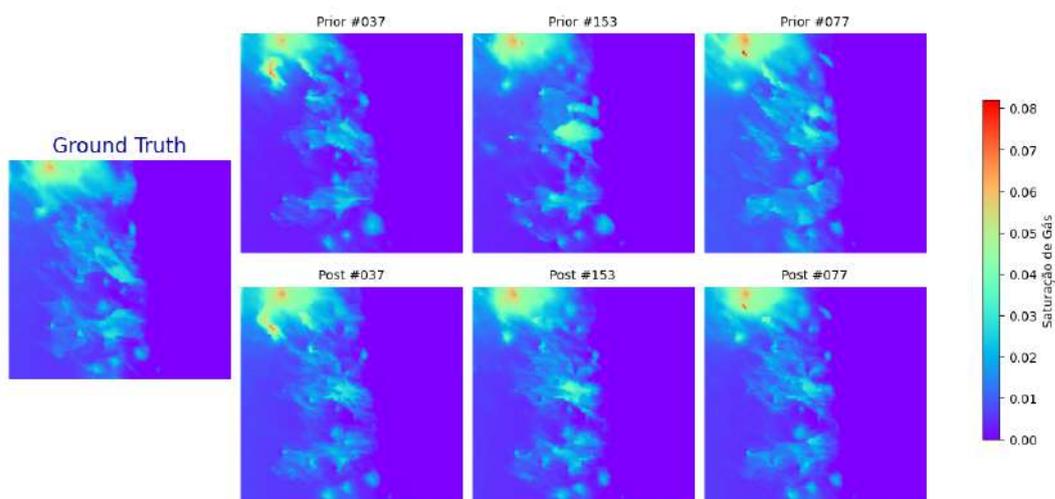


Figura 5.81: Mapas de saturação de gás da camada 01 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

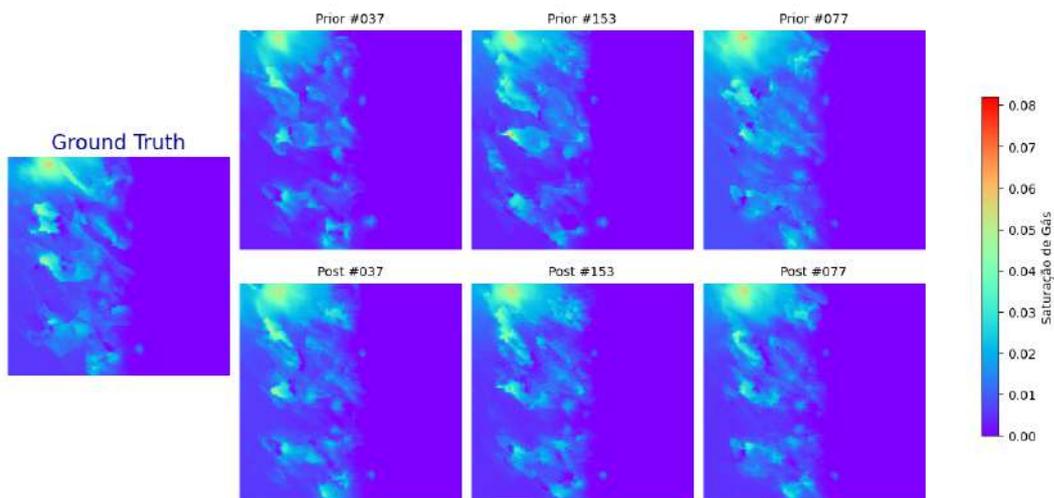


Figura 5.82: Mapas de saturação de gás da camada 02 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

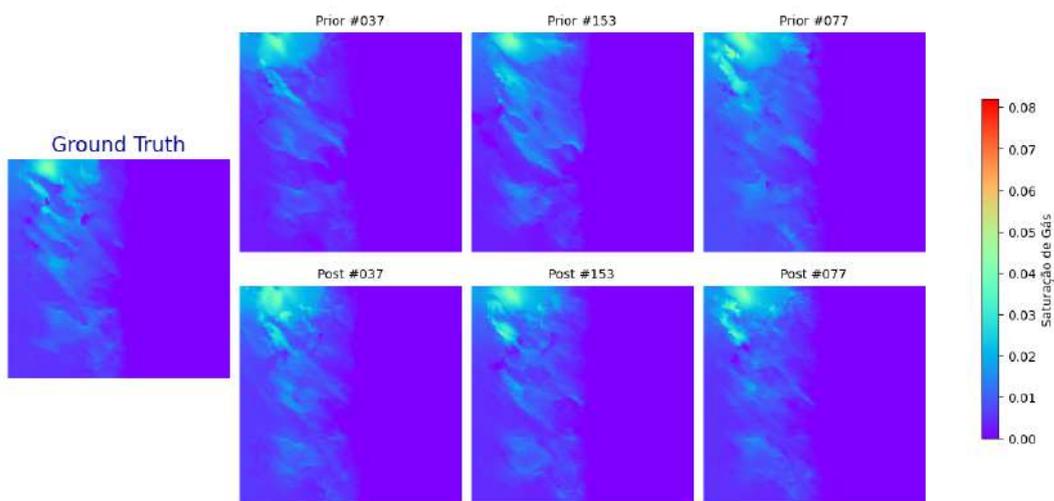


Figura 5.83: Mapas de saturação de gás da camada 03 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

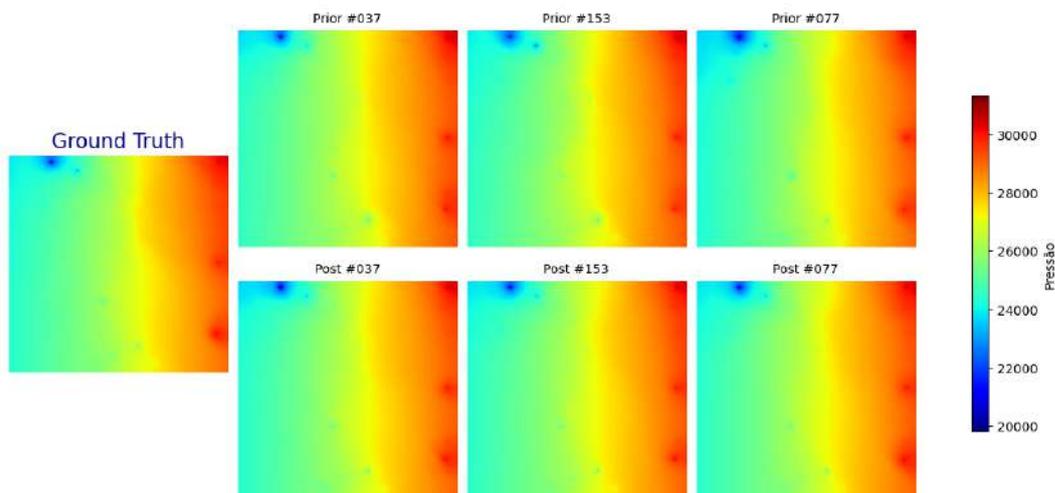


Figura 5.84: Mapas de pressão da camada 01 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

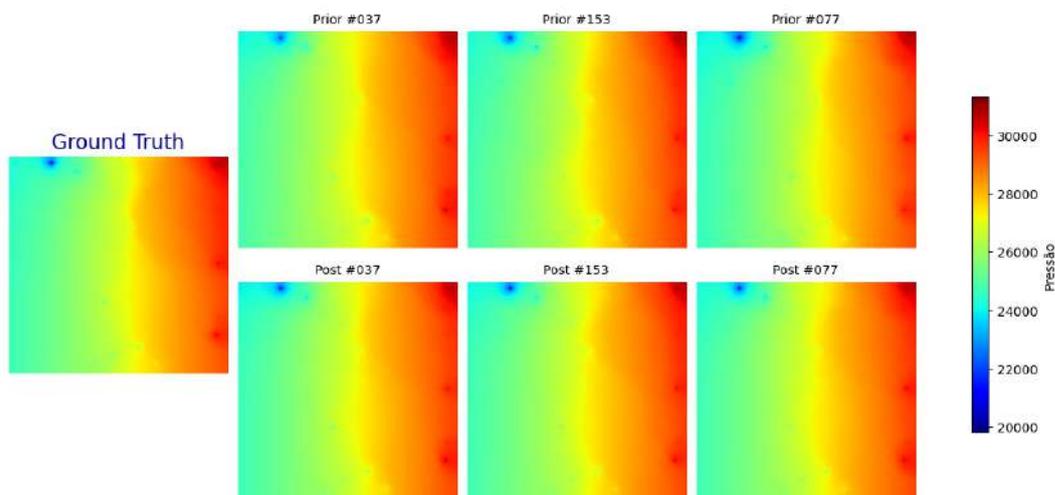


Figura 5.85: Mapas de pressão da camada 02 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

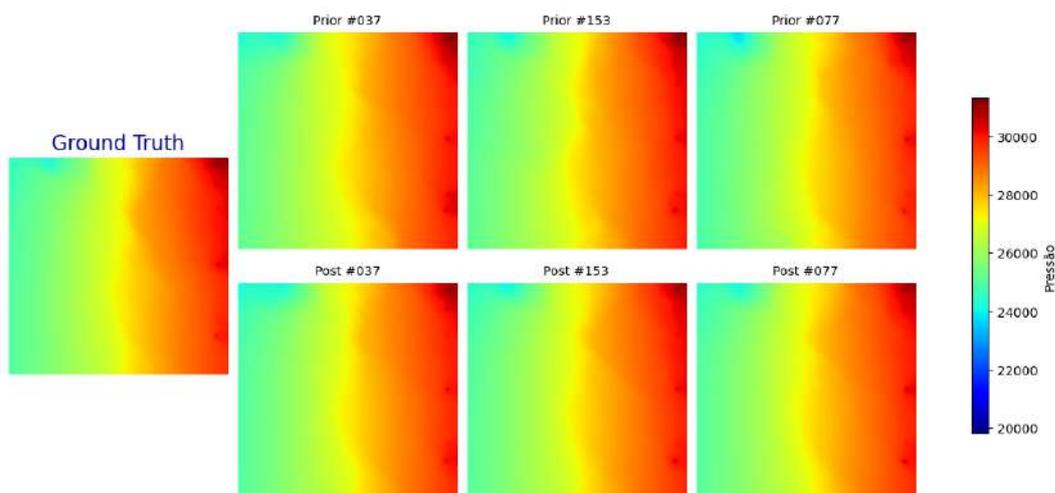


Figura 5.86: Mapas de pressão da camada 03 do caso de estudo 2B comparando o reservatório de referência (*ground truth*) com três das realizações *a priori* (superior) e suas respectivas realizações *a posteriori* (inferior).

Portanto, pode-se considerar que a metodologia proposta neste trabalho obteve sucesso em todos os casos avaliados, ao permitir o ajuste indireto de uma propriedade categórica (fácies), através da transformação das propriedades ajustadas pelo método ES-MDA por uma rede de tradução I2I, adaptada para tal propósito. Considerando os resultados expostos, é razoável afirmar que o assunto merece ser alvo de estudos adicionais, havendo um amplo espaço para discussões e futuras pesquisas, que serão tratados no capítulo 6.

6

Conclusões e Recomendações

A incorporação de dados históricos a modelos de reservatórios é uma etapa fundamental para a evolução do conhecimento de uma jazida, proporcionando um aprimoramento contínuo dos processos de estimativa da produção e de tomada de decisão durante o desenvolvimento e o gerenciamento de um campo de petróleo. Técnicas que busquem tornar o processo mais ágil e eficiente se fazem necessárias, podendo-se destacar, dentre os avanços recentes na área, o método *ensemble smoother with multiple data assimilation* (ES-MDA).

Neste contexto, a principal contribuição deste trabalho foi a de propor uma alternativa que pudesse ser acoplada ao método ES-MDA de forma a melhorar seu desempenho ao realizar o ajuste de parâmetros representados por valores categóricos, como as classes de fácies geológicas. Para que isso fosse viabilizado, ao longo da pesquisa buscou-se investigar soluções envolvendo técnicas de aprendizado profundo (*deep learning*) para tratar do problema, mais especificamente na área de tradução imagem-imagem (I2I). A motivação para esta escolha foi aliar a similaridade entre as representações matriciais de uma imagem e a estrutura em malha das propriedades no modelo de reservatório ao excelente desempenho que as redes generativas profundas tem demonstrado em trabalhos recentes envolvendo a tarefa de tradução I2I.

Ao longo desta dissertação, foi apresentada uma breve fundamentação sobre o processo de ajuste de histórico de modelos de reservatórios, com foco numa abordagem assistida, na qual o método ES-MDA tem se destacado entre as demais. Em seguida, investigou-se o estado da arte das técnicas de tradução I2I, sendo selecionada uma das arquiteturas disponíveis, a rede **pix2pix**, para a condução dos estudos. Foram então apresentados alguns exemplos presentes na literatura da aplicação de redes de aprendizado profundo (*deep learning*) na área de ajuste de histórico e, por fim, foi abordada analogia entre as representações de imagens e o modelo de reservatórios. Tendo esse arcabouço teórico consolidado, propôs-se o acoplamento da rede I2I ao processo de ajuste assistido para permitir o ajuste indireto de uma propriedade categórica, após a transformação das propriedades contínuas realizada pelo método ES-MDA.

Para avaliar a eficácia da metodologia proposta, inicialmente foram construídos conjuntos de modelos de reservatórios, definidos casos de estudo

e selecionadas métricas para análise. Então, foi realizado o treinamento das redes I2I, de forma a traduzir os atributos contínuos (porosidade e permeabilidades) na propriedade categórica de interesse (fácies geológicas). Ao final, do treinamento foi realizado o processo de assimilação de dados aos modelos de reservatórios, cujos resultados foram discutidos para cada caso de estudo.

Os resultados obtidos após a aplicação da metodologia demonstraram, em geral, a boa capacidade de generalização da rede de tradução I2I ao fornecer realizações de fácies aderentes às características geológicas dos reservatórios de referência e cujas respostas simuladas estejam ajustadas aos dados históricos de produção, o que potencialmente confere uma maior confiabilidade à previsão de produção destes modelos.

Ampliando a discussão sobre os resultados, nos cenários em que os modelos de fácies apresentam características mais complexas, como nas realizações geológicas representando canais dos casos de estudo 1A e 1B, percebeu-se que, apesar dos formatos das estruturas geológicas principais terem sido bem representados, há um certo grau de granularidade no aspecto de algumas fácies. Supõe-se que este efeito tenha sido reforçado pela natureza do cenário, na qual os parâmetros dos modelos *a priori* apresentam intrinsecamente um caráter não gaussiano, deteriorando o desempenho do método ES-MDA. Acredita-se que este fato possa ser atenuado, avaliando redes I2I cuja arquitetura seja composta por módulos que realizem o processo de tradução explorando um espaço latente com características gaussianas, como por exemplo a adoção de redes *Variational Autoencoders*¹ (VAE) em seu módulo gerador.

Neste sentido, o método proposto por Arauco Canchumuni et al. [2, 3], descrito na seção 4, apresentaria uma vantagem ao lidar com modelos onde as propriedades contínuas (porosidade e permeabilidade) também se afastam de uma caracterização gaussiana *a priori* (discutido na seção 5.4.2.3), pois a tradução do parâmetro original em uma representação numérica adicional, com distribuição normal, tornaria mais eficiente a execução do método ES-MDA.

Por outro lado, mesmo nestes cenários de maior complexidade, os resultados obtidos ao utilizar a rede de tradução I2I foram consistentes, reproduzindo nos modelos *a posteriori* a continuidade das principais feições geológicas do reservatório de referência, condição importante para uma melhor caracteriza-

¹VAE é uma rede de *autoencoder* cuja codificação em seu espaço latente é regularizada durante o treinamento, a fim de garantir que se caracterize por uma distribuição gaussiana.

ção espacial dos estados dinâmicos (saturações e pressões) no modelo, cuja adequada representação é de grande relevância para a definição da locação de poços complementares em uma jazida, potencialmente permitindo uma melhor caracterização das incertezas durante a avaliação deste tipo de projeto.

Outro aspecto importante é que a metodologia de tradução I2I permite que o método ES-MDA ajuste os próprios parâmetros de malha do modelo de reservatórios, sem a necessidade de uma propriedade adicional. Apesar de ser robusto o suficiente quanto ao aumento do número de parâmetros, o método ES-MDA ganha em desempenho ao ser associado à técnica de localização da covariância, discutida na seção 2.2.2, a qual pressupõe que a propriedade a ser ajustada mantenha a representação espacial do modelo de reservatórios, o que não é garantido ao se integrar uma rede que codifique uma propriedade gaussiana complementar.

Além disso, a adoção da abordagem de tradução I2I se mostra relevante ao tornar desnecessário o desenvolvimento de uma rede específica para cada problema de ajuste de histórico - a qual demandaria a otimização de sua estrutura e de seu método de treinamento - podendo-se todavia recorrer diretamente a arquiteturas de tradução I2I amplamente referenciadas na literatura e, portanto, beneficiando-se da contínua evolução de eficiência e desempenho destas redes ao incorporá-las à tarefa de assimilação de dados a modelos de reservatórios.

Por fim, considerando os resultados expostos e as reflexões conduzidas ao longo da pesquisa, podem ser sugeridos alguns tópicos para estudo adicional, fomentando o avanço da integração das redes de aprendizado profundo à modelagem de reservatórios, cujo potencial ainda deve ser melhor explorado, dentre os quais podem ser mencionados:

- avaliar o desempenho da metodologia utilizando outras arquiteturas de rede I2I;
- expandir a rede para a utilização em um número maior de camadas do modelo de reservatório, uma vez que o presente estudo considerou um número máximo de três camadas, de forma a não haver grandes modificações na topologia da rede;
- analisar o impacto da otimização dos hiperparâmetros de treinamento da rede, buscando melhorias de desempenho e redução de tempo de treino;

- propor estratégias robustas de transferência de aprendizado (*transfer learning*) [59], de forma a permitir o treinamento da rede por um conjunto menor de realizações, partindo de uma rede pré-treinada, com o benefício potencial de se perpetuar o aprendizado da rede ao longo do processo de ajuste de versões anteriores do modelo;
- explorar arquiteturas de rede para síntese de imagem que possuam mecanismos de atenção [57], com o objetivo de condicionar a influência dos dados a sub-regiões específicas do modelo (atuando de forma análoga à localização da covariância, discutida na seção 2.2.2); e
- investigar a viabilidade de modificações no método ES-MDA, de forma a incorporar a rede diretamente ao processo de determinação do ganho de Kalman (equação 2-11), avaliando, por exemplo, se há benefícios ao se aproveitar da capacidade de generalização espacial destas redes para também correlacionar as informações contidas nos estados dinâmicos do conjunto dos modelos (saturação e pressão) à magnitude das alterações nos parâmetros ajustados ao longo da assimilação de dados.

Referências bibliográficas

- [1] AGUIRRE, L. A. *Introdução à identificação de sistemas: técnicas lineares e não lineares: teoria e aplicação*. Editora UFMG, Belo Horizonte, 2015. Citado na página 30.
- [2] ARAUCO CANCHUMUNI, S., EMERICK, A. A., E PACHECO, M. A. Integration of ensemble data assimilation and deep learning for history matching facies models. In *OTC Brasil (2017)*, OnePetro. Citado 5 vezes nas páginas 24, 46, 48, 49 e 107.
- [3] ARAUCO CANCHUMUNI, S. W. *Método híbrido baseado em filtro de Kalman e modelos generativos de aprendizagem profunda no ajuste de histórico sob incertezas para modelos de fácies geológicas*. Tese de doutorado, PUC-Rio, Rio de Janeiro (BRA), 2017. Citado 4 vezes nas páginas 24, 46, 49 e 107.
- [4] BEUCHER, H., E RENARD, D. Truncated gaussian and derived methods. *Comptes Rendus Geoscience* 348, 7 (2016), 510–519. Citado na página 55.
- [5] CHITHRA CHAKRA, N. C., E SARAF, D. N. History matching of petroleum reservoirs employing adaptive genetic algorithm. *Journal of Petroleum Exploration and Production Technology* (2015). Citado 3 vezes nas páginas 23, 24 e 29.
- [6] CHO, K., VAN MERRIËNBOER, B., BAHDANAU, D., E BENGIO, Y. On the properties of neural machine translation: Encoder-decoder approaches. *arXiv preprint arXiv:1409.1259* (2014). Citado na página 35.
- [7] DURALL, R., CHATZIMICHAILIDIS, A., LABUS, P., E KEUPER, J. Combating mode collapse in gan training: An empirical analysis using hessian eigenvalues. *arXiv preprint arXiv:2012.09673* (2020). Citado na página 64.
- [8] EAKINS, J. P., E GRAHAM, M. E. Content-based image retrieval, a report to the jisc technology applications programme, 1999. Citado na página 34.
- [9] EMERICK, A. A., E REYNOLDS, A. C. Combining sensitivities and prior information for covariance localization in the ensemble Kalman filter for petroleum reservoir applications. *Computational Geosciences* (2011). Citado 2 vezes nas páginas 33 e 118.

- [10] EMERICK, A. A., E REYNOLDS, A. C. History matching a field case using the ensemble Kalman filter with covariance localization. *SPE Reservoir Evaluation & Engineering* (2011). Citado na página 33.
- [11] EMERICK, A. A., E REYNOLDS, A. C. Ensemble smoother with multiple data assimilation. *Computers & Geosciences* (2013). Citado 3 vezes nas páginas 24, 31 e 48.
- [12] FOSSUM, K. *Assessment of Sequential and Simultaneous Ensemble-based History Matching Methods for Weakly Non-linear Problems*. Tese de doutorado, University of Bergen, Bergen (NO), 2015. Citado na página 32.
- [13] GEIR, N., MANNSETH, T., E VEFRING, E. H. Near-well reservoir monitoring through ensemble kalman filter. In *SPE/DOE improved oil recovery symposium* (2002), OnePetro. Citado na página 23.
- [14] GOODFELLOW, I., BENGIO, Y., E COURVILLE, A. *Deep Learning*. The MIT Press, Massachusetts (USA), 2016. Citado na página 35.
- [15] GOODFELLOW, I. J., POUGET-ABADIE, J., MIRZA, M., XU, B., WARDE-FARLEY, D., OZAIR, S., COURVILLE, A., E BENGIO, Y. Generative adversarial networks. *arXiv preprint arXiv:1406.2661* (2014). Citado na página 37.
- [16] HARE, J. S., LEWIS, P. H., ENSER, P. G., E SANDOM, C. J. Mind the gap: Another look at the problem of the semantic gap in image retrieval. In *Multimedia Content Analysis, Management, and Retrieval 2006* (2006), vol. 6073, SPIE, pp. 75–86. Citado na página 35.
- [17] ISOLA, P., ZHU, J.-Y., ZHOU, T., E EFROS, A. A. Image-to-image translation with conditional adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (2017), pp. 1125–1134. Citado 3 vezes nas páginas 10, 41 e 43.
- [18] JANSEN, J. D., DOUMA, S. D., BROUWER, D. R., VAN DEN HOF, P. M. J., BOSGRA, O. H., E HEEMINK, A. W. Closed-loop reservoir management. *SPE 119098* (2009). Citado 2 vezes nas páginas 23 e 29.
- [19] JOHANSEN, K. *Statistical Methods for History Matching*. Frydenberg AS, Copenhagen (DK), 2008. Citado 2 vezes nas páginas 23 e 29.
- [20] KALMAN, R. E. A new approach to linear filtering and prediction problems. Citado na página 23.

- [21] KENNEDY, J., E EBERHART, R. Particle swarm optimization. *IEEE ICNN* (1995). Citado na página 29.
- [22] KILLOUGH, J. Ninth SPE comparative solution project: a reexamination of black-oil simulation. In *SPE Reservoir Simulation Symposium* (1995), OnePetro. Citado na página 51.
- [23] KINGMA, D. P., E BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980* (2014). Citado na página 64.
- [24] KRAUSE, E. F. *Taxicab geometry: An adventure in non-Euclidean geometry*. Courier Corporation, 1986. Citado na página 62.
- [25] LECUN, Y., BENGIO, Y., ET AL. Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks* 3361, 10 (1995), 1995. Citado 2 vezes nas páginas 10 e 35.
- [26] LONG, J., SHELHAMER, E., E DARRELL, T. Fully convolutional networks for semantic segmentation. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Boston, MA, USA, Jun 2015), IEEE, p. 3431–3440. Citado 2 vezes nas páginas 25 e 35.
- [27] LOWE, D. G. Three-dimensional object recognition from single two-dimensional images. *Artificial Intelligence* 31, 3 (Mar 1987), 355–395. Citado na página 34.
- [28] MARR, D. Representing visual information. Citado na página 34.
- [29] MARR, D. *Vision*. W.H. Freeman and Co., 1982. Citado na página 34.
- [30] MIRZA, M., E OSINDERO, S. Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784* (2014). Citado na página 38.
- [31] MOHAMED, L., CHRISTIE, M., DEMYANOV, V., ROBERT, E., E KACHUMA, D. Application of particle swarms for history matching in the brugge reservoir. *SPE 135264* (2010). Citado 2 vezes nas páginas 23 e 29.
- [32] MONFARED, A. D., HELALIZADEH, A., E PARVIZI, H. Automatic history matching using the integration of response surface modeling with a genetic algorithm. *Petroleum Science and Technology* (2011). Citado 3 vezes nas páginas 23, 24 e 29.
- [33] MOSSER, L., DUBRULE, O., E BLUNT, M. J. Stochastic seismic waveform inversion using generative adversarial networks as a geological prior. *Mathematical Geosciences* 52, 1 (2018), 53–79. Citado na página 46.

- [34] MOSSER, L., DUBRULE, O., E BLUNT, M. J. Deepflow: history matching in the space of deep generative models. *arXiv preprint arXiv:1905.05749* (2019). Citado 2 vezes nas páginas 24 e 46.
- [35] NEELAKANTAN, P. Comparison of multi-model history matching methods. Dissertação de mestrado, Delft University of Technology, Delft (NL), 2017. Citado na página 29.
- [36] NICHOLS, G. *Sedimentology and stratigraphy*. John Wiley & Sons, 2009. Citado 3 vezes nas páginas 10, 53 e 54.
- [37] OLIVER, D. S., REYNOLDS, A. C., E LIU, N. *Inverse Theory for Petroleum Reservoir Characterization and History Matching*. Cambridge University Press, Cambridge (UK), 2008. Citado 4 vezes nas páginas 23, 27, 29 e 30.
- [38] PANG, Y., LIN, J., QIN, T., E CHEN, Z. Image-to-image translation: Methods and applications. *IEEE Transactions on Multimedia* (2021). Citado 3 vezes nas páginas 34, 42 e 120.
- [39] PATHAK, D., KRAHENBUHL, P., DONAHUE, J., DARRELL, T., E EFROS, A. A. Context encoders: Feature learning by inpainting. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (June 2016). Citado na página 35.
- [40] REYNOLDS, A. P., ABDOLLAHZADEH, A., CORNE, D. W., CHRISTIE, M., DAVIES, B., E WILLIAMS, G. Guide objective assisted particle swarm optimization and its application to history matching. *PPSN* (2012). Citado 2 vezes nas páginas 23 e 29.
- [41] RODRIGUES, J. R. P. Calculating derivatives for automatic history matching. *Computational Geosciences 10* (2006), 119–136. Citado na página 29.
- [42] RONNEBERGER, O., FISCHER, P., E BROX, T. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18* (2015), Springer, pp. 234–241. Citado na página 36.
- [43] SCHMARJE, L., SANTAROSSA, M., SCHRÖDER, S.-M., E KOCH, R. A survey on semi-, self-and unsupervised learning for image classification. *IEEE Access 9* (2021), 82146–82168. Citado na página 40.

- [44] SEBACHER, M. B. *Data Assimilation under Geological Constraints*. Tese de doutorado, Delft University of Technology, Delft (NL), 2014. Citado na página 24.
- [45] SHI, J., E MALIK, J. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 22, 8 (2000), 18. Citado na página 34.
- [46] SILVA, V. L. S. Ajuste de histórico e otimização da produção de petróleo sob incertezas - aplicação do gerenciamento de reservatórios em malha fechada. Dissertação de mestrado, Universidade Federal do Rio de Janeiro - UFRJ, Rio de Janeiro, 2016. Citado 4 vezes nas páginas 24, 28, 33 e 116.
- [47] SIMMON, R., E ALLEN, J. Yukon delta. <https://earthobservatory.nasa.gov/images/72762/yukon-delta-alaska>. Accessed: 2023-03-01. Citado 2 vezes nas páginas 10 e 54.
- [48] SKJERVHEIM, J., E EVENSEN, G. An ensemble smoother for assisted history matching. *SPE 141929* (2011). Citado na página 31.
- [49] SMITH, G. Upscaling of grid properties in reservoir simulation. https://petrowiki.spe.org/Upscaling_of_grid_properties_in_reservoir_simulation. Accessed: 2023-03-01. Citado 2 vezes nas páginas 10 e 58.
- [50] STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. *Remote sensing of Environment* 62, 1 (1997), 77–89. Citado na página 63.
- [51] TAKAFUJI, E. H. M., ROCHA, M. M., E RAMOS, G. Z. Estudo comparativo dos métodos de simulação SNESIM e FILTERSIM – aplicado a um modelo sintético de cobre. *Boletim Paranaense de Geociências, Vol. 74 (UFPR)* (2018). Citado na página 55.
- [52] TARANTOLA, A. *Inverse problem theory and methods for model parameter estimation*. SIAM, 2005. Citado na página 27.
- [53] WANG, Z., BOVIK, A. C., SHEIKH, H. R., E SIMONCELLI, E. P. Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing* 13, 4 (2004), 600–612. Citado na página 62.
- [54] WU, A. A new integrated approach of natural fracture modelling to improve historical matching and prediction for devonian carbonate reservoirs

- in Nenetskoye oil field, Russia. *Petrovietnam Journal* (2018). Citado na página 24.
- [55] XAVIER, C. R., SANTOS, E. P., VIEIRA, V. F., E SANTOS, R. W. Genetic algorithm for the history matching problem. *Procedia Computer Science* (2013). Citado 3 vezes nas páginas 23, 24 e 29.
- [56] XIA, W., YANG, Y., E XUE, J.-H. Unsupervised multi-domain multimodal image-to-image translation with explicit domain-constrained disentanglement. *Neural Networks 131* (2020), 50–63. Citado 2 vezes nas páginas 10 e 42.
- [57] XU, T., ZHANG, P., HUANG, Q., ZHANG, H., GAN, Z., HUANG, X., E HE, X. Attngan: Fine-grained text to image generation with attentional generative adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (2018), pp. 1316–1324. Citado na página 109.
- [58] YAN-LIN, S., AI-LING, Z., YOU-BIN, H., E KE-YAN, X. 3D geological modeling and its application under complex geological conditions. *Procedia Engineering 12* (2011), 41–46. Citado na página 53.
- [59] YAQUB, M., JINCHAO, F., AHMED, S., ARSHID, K., BILAL, M. A., AKHTER, M. P., E ZIA, M. S. Gan-tl: Generative adversarial networks with transfer learning for mri reconstruction. *Applied Sciences 12*, 17 (2022), 8841. Citado na página 109.
- [60] ZHANG, R., ISOLA, P., E EFROS, A. A. Colorful image colorization. In *European conference on computer vision* (2016), Springer, pp. 649–666. Citado na página 35.
- [61] ZHAO, Y., FOROUZANFAR, F., E REYNOLDS, A. C. Assisted history matching for multi-facies channelized reservoir using es-mda with common basis DCT. *ECMOR XV* (2016). Citado na página 24.
- [62] ZHU, J.-Y., PARK, T., ISOLA, P., E EFROS, A. A. Unpaired image-to-image translation using cycle-consistent adversarial networks. In *Proceedings of the IEEE international conference on computer vision* (2017), pp. 2223–2232. Citado 3 vezes nas páginas 10, 40 e 41.
- [63] ZHU, J.-Y., ZHANG, R., PATHAK, D., DARRELL, T., EFROS, A. A., WANG, O., E SHECHTMAN, E. Toward multimodal image-to-image translation. *Advances in neural information processing systems 30* (2017). Citado 2 vezes nas páginas 10 e 41.

A

Algoritmo ES-MDA

O algoritmo, em pseudocódigo, para a aplicação do método ES-MDA na assimilação de dados a modelos de reservatórios é descrito a seguir (adaptado de [46]):

1. Inicialização:

- Definir o conjunto de realizações (modelos) *a priori* $\{\mathbf{m}_j^0\}_{j=1}^{N_m}$, sendo:

$$\mathbf{m}_j^0 = [m_{j,1}^0 \quad m_{j,2}^0 \quad \dots \quad m_{j,N_p}^0]^T, \quad (\text{A-1})$$

onde N_m é o número de modelos *a priori* e N_p é o número de parâmetros do modelo;

- Definir vetor de dados históricos medidos \mathbf{d}_{hist} , com dimensão N_d (número total de dados):

$$\mathbf{d}_{hist} = [d_{hist_1} \quad d_{hist_2} \quad \dots \quad d_{hist_{N_d}}]^T; \quad (\text{A-2})$$

- Definir a matriz covariância do ruído nos dados medidos \mathbf{C}_D , de dimensão $N_d \times N_d$. Esta é uma matriz cujos os elementos de sua diagonal principal correspondem às variâncias do ruído em cada um dos dados históricos medidos. Assumindo-se que os ruídos nos dados são independentes, os demais elementos da matriz são nulos:

$$\mathbf{C}_D = \begin{bmatrix} \sigma_{d_{hist_1}}^2 & 0 & \dots & 0 \\ 0 & \sigma_{d_{hist_2}}^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{d_{hist_{N_d}}}^2 \end{bmatrix}; \quad (\text{A-3})$$

- Definir o número de iterações para assimilação de dados N_a ; e
- Definir os fatores de inflação α_ℓ , para $\ell = 1, 2, \dots, N_a$, condicionados a seguinte restrição:

$$\sum_{\ell=1}^{N_a} \frac{1}{\alpha_\ell} = 1. \quad (\text{2-8})$$

2. Método ES-MDA:

Considere o conjunto de parâmetros de entrada $\{\mathbf{m}_j^0, \mathbf{d}_{hist}, \mathbf{C}_D, N_a, \alpha_\ell\}$.

Para $\ell = 1$ até N_a , faça:

- Executar a simulação dos modelos do conjunto $\{\mathbf{m}_j^{\ell-1}\}_{j=1}^{N_m}$, do tempo zero até o final do histórico de dados, para gerar o vetor de dados simulados $\mathbf{d}_j^{\ell-1}$ do j -ésimo modelo na iteração $(\ell - 1)$:

$$\mathbf{d}_j^{\ell-1} = \mathbf{g}(\mathbf{m}_j^{\ell-1}), \quad \text{para } j = 1, 2, \dots, N_m. \quad (\text{A-4})$$

- Estimar as matrizes de covariância \mathbf{C}_S ($N_d \times N_d$) e \mathbf{C}_{MS} ($N_p \times N_d$), a partir do conjunto de modelos e seus respectivos dados simulados:

$$\mathbf{C}_S^\ell = \frac{1}{N_m - 1} \sum_{j=1}^{N_m} (\mathbf{d}_j^{\ell-1} - \bar{\mathbf{d}}^\ell)(\mathbf{d}_j^{\ell-1} - \bar{\mathbf{d}}^\ell)^T, \quad (\text{A-5})$$

$$\mathbf{C}_{MS}^\ell = \frac{1}{N_m - 1} \sum_{j=1}^{N_m} (\mathbf{m}_j^{\ell-1} - \bar{\mathbf{m}}^\ell)(\mathbf{d}_j^{\ell-1} - \bar{\mathbf{d}}^\ell)^T, \quad (\text{A-6})$$

onde

$$\bar{\mathbf{d}}^\ell = \frac{1}{N_m} \sum_{j=1}^{N_m} \mathbf{d}_j^{\ell-1} \quad \text{e} \quad \bar{\mathbf{m}}^\ell = \frac{1}{N_m} \sum_{j=1}^{N_m} \mathbf{m}_j^{\ell-1}. \quad (\text{A-7})$$

- Perturbar o vetor de dados históricos \mathbf{d}_{hist} com um ruído aleatório $\boldsymbol{\varepsilon}_j$ da seguinte forma:

$$\boldsymbol{\varepsilon}_j^\ell = \sqrt{\alpha_\ell} \mathbf{C}_D^{1/2} \mathbf{z}_j, \quad (\text{A-8})$$

$$\mathbf{d}_{hist,j}^\ell = \mathbf{d}_{hist} + \boldsymbol{\varepsilon}_j^\ell, \quad (\text{A-9})$$

para $j = 1, 2, \dots, N_m$ e onde \mathbf{z}_j é um vetor coluna aleatório com dimensão N_d , amostrado com uma distribuição normal de média zero e desvio padrão um ($\mathcal{N}(0, 1)$).

- Atualizar o vetor de parâmetros do modelo \mathbf{m}_j^ℓ , para $j = 1, 2, \dots, N_m$:

$$\mathbf{m}_j^\ell = \mathbf{m}_j^{\ell-1} + \mathbf{C}_{MS}^\ell (\mathbf{C}_S^\ell + \alpha_\ell \mathbf{C}_D)^{-1} (\mathbf{d}_{hist,j}^\ell - \mathbf{d}_j^{\ell-1}). \quad (\text{2-9})$$

Fim Para

Fim Método

Ao final, temos o conjunto de modelos *a posteriori* ajustados $\{\mathbf{m}_j^{N_a}\}_{j=1}^{N_m}$.

B Matriz de Localização da Covariância

A construção da matriz de localização da covariância \mathbf{R}_{MD} [9], com dimensão $N_p \times N_d$, a partir da função de Gaspari e Cohn, se inicia com a definição das distâncias críticas L_1 e L_2 , além do ângulo θ , que definirão uma elipse de influência em torno da localização espacial na qual o dado foi medido, como por exemplo a localização do poço na malha do modelo, representado na figura B.1 pelas coordenadas (x_0, y_0) .

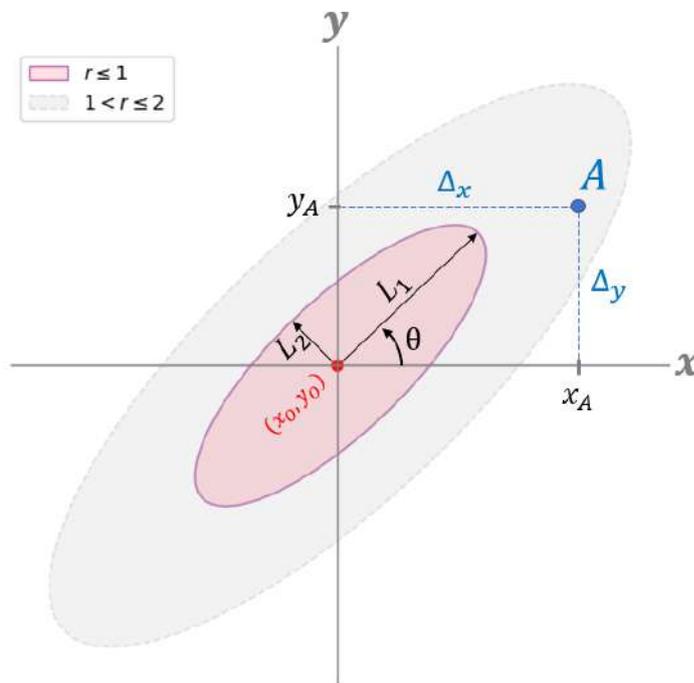


Figura B.1: Localização da Covariância.

Supondo que se deseje calcular o elemento $[\mathbf{R}_{\text{MD}}]_{ij}$ da matriz, que define a influência do j -ésimo dado histórico sobre o i -ésimo parâmetro do modelo, este localizado no ponto A com coordenadas (x_A, y_A) .

Considerando as distâncias Δ_x e Δ_y do ponto A até os eixos de coordenadas, realiza-se a rotação em relação à inclinação θ da elipse:

$$\begin{bmatrix} \Delta'_x \\ \Delta'_y \end{bmatrix} = \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} \Delta_x \\ \Delta_y \end{bmatrix}, \quad \begin{cases} \Delta_x = x_A - x_0 \\ \Delta_y = y_A - y_0 \end{cases} \quad (\text{B-1})$$

Por fim, utiliza-se a função de Gaspari-Cohn para determinar o valor do elemento correspondente na matriz de localização da covariância, fazendo $[\mathbf{R}_{\text{MD}}]_{ij} = G_c(r_{ij})$, tal que:

$$G_c(r) = \begin{cases} -\frac{1}{4}r^5 + \frac{1}{2}r^4 + \frac{5}{8}r^3 - \frac{5}{3}r^2 + 1 & 0 \leq r \leq 1 \\ \frac{1}{12}r^5 - \frac{1}{2}r^4 + \frac{5}{8}r^3 + \frac{5}{3}r^2 - 5r + 4 - \frac{2}{3}r^{-1} & 1 < r \leq 2 \\ 0 & r > 2 \end{cases}, \quad (\text{B-2})$$

tal que $r = \sqrt{\left(\frac{\Delta'_x}{L_1}\right)^2 + \left(\frac{\Delta'_y}{L_2}\right)^2}$.

Com a matriz \mathbf{R}_{MD} construída pode-se recorrer à equação 2-13 para utilizar à técnica de localização da covariância durante o processo de assimilação de dados pelo ES-MDA.

C

Redes para Tradução Imagem-imagem

A tabela C.1 descreve algumas redes de tradução imagem-imagem e suas características básicas [38]:

Tabela C.1: Redes I2I.

Rede	Publicação	Aprendizado	Multimodal	Multidomínio
pix2pix	2017	Supervisionado	Não	Não
DRPAN	2018	Supervisionado	Não	Não
pix2pixHD	2018	Supervisionado	Não	Não
SelectionGAN	2019	Supervisionado	Não	Não
SPADE	2019	Supervisionado	Não	Não
SEAN	2020	Supervisionado	Não	Não
CoCosNet	2020	Supervisionado	Não	Não
CoCosNetv2	2021	Supervisionado	Não	Não
ASAPNet	2021	Supervisionado	Não	Não
BicycleGAN	2017	Supervisionado	Sim	Não
PixelNN	2018	Supervisionado	Sim	Não
TCR	2020	Semi-supervisionado	Não	Não
DTN	2016	Não-supervisionado	Não	Não
DualGAN/DiscoGAN/CycleGAN	2017	Não-supervisionado	Não	Não
UNIT	2017	Não-supervisionado	Não	Não
SCAN	2018	Não-supervisionado	Não	Não
U-GAT-IT	2019	Não-supervisionado	Não	Não
GANimorph	2018	Não-supervisionado	Não	Não
TraVeLGAN	2019	Não-supervisionado	Não	Não
TransGaGa	2019	Não-supervisionado	Não	Não
ACL-GAN	2020	Não-supervisionado	Não	Não
DistanceGAN	2017	Não-supervisionado	Não	Não
GCGAN	2019	Não-supervisionado	Não	Não
CUT	2020	Não-supervisionado	Não	Não
TSIT	2020	Não-supervisionado	Não	Não
F-LSeSim	2021	Não-supervisionado	Não	Não
LPTN	2021	Não-supervisionado	Não	Não
DAGAN	2018	Não-supervisionado	Não	Não
Attention-GAN/	2018	Não-supervisionado	Não	Não
Attention-guided I2I	2018	Não-supervisionado	Não	Não
InstaGAN	2018	Não-supervisionado	Não	Não
DUNIT	2020	Não-supervisionado	Sim	Não
Art2real	2019	Não-supervisionado	Não	Não
GDWCT	2019	Não-supervisionado	Não	Não
DAI2I	2020	Não-supervisionado	Não	Não
NICE-GAN	2020	Não-supervisionado	Não	Não
MSGAN	2019	Não-supervisionado	Sim	Não
DeepI2I	2020	Transfer Learning	Não	Não
Domain-Bank/ModularGAN	2018	Não-supervisionado	Não	Sim
StarGAN	2018	Não-supervisionado	Não	Sim

Rede	Publicação	Aprendizado	Multimodal	Multidomínio
cd-GAN/MUNIT/DRIT/EGSC-IT	2018	Não-supervisionado	Sim	Não
AttGAN	2019	Não-supervisionado	Não	Sim
RelGAN/STGAN	2019	Não-supervisionado	Não	Sim
CollaGAN	2019	Não-supervisionado	Não	Sim
SGN	2019	Não-supervisionado	Não	Sim
Fixed-Point GAN	2019	Não-supervisionado	Não	Sim
ADSPM	2019	Não-supervisionado	Não	Sim
GANimation	2018	Não-supervisionado	Sim	Sim
DosGAN	2019	Não-supervisionado	Sim	Sim
UFDN	2018	Não-supervisionado	Sim	Sim
DMIT	2019	Não-supervisionado	Sim	Sim
StarGANv2	2020	Não-supervisionado	Sim	Sim
DRIT++	2020	Não-supervisionado	Sim	Sim
GMM-UNIT	2020	Não-supervisionado	Sim	Sim
FUNIT	2019	Não-supervisionado	Sim	Sim
COCO-FUNIT	2020	Não-supervisionado	Sim	Sim
AGUIT	2019	Semi-supervisionado	Sim	Sim
SEMIT	2020	Semi-supervisionado	Não	Sim

D

Curvas de Permeabilidade Relativa

As tabelas D.1, D.2 e D.1 apresentam as curvas de permeabilidade relativa óleo-água e gás-líquido das fácies de baixa, média e alta energia, respectivamente, adotadas no presente estudo:

Tabela D.1: Curvas de permeabilidade relativa das fácies 1 (baixa energia).

Sw	Krw	Krow	Sl	Krg	Krog
0.15	0	0.4	0.15	1	0
0.1675	0.008203	0.351859	0.1925	0.9405	0
0.185	0.024868	0.307373	0.235	0.881	0
0.2025	0.047575	0.266445	0.2775	0.8215	0
0.22	0.075385	0.228973	0.32	0.762	0
0.2375	0.107731	0.194856	0.3625	0.7025	0
0.255	0.144221	0.163985	0.405	0.643	0
0.2725	0.184563	0.136252	0.4475	0.5835	0
0.29	0.228524	0.111542	0.49	0.524	0
0.3075	0.275915	0.089736	0.5325	0.4645	0
0.325	0.326578	0.070711	0.575	0.405	0
0.3425	0.380378	0.054336	0.6175	0.3455	0
0.36	0.437197	0.040477	0.65	0.3	0
0.3775	0.496932	0.028989	0.68125	0.206372	0.000953
0.395	0.55949	0.019718	0.72375	0.116428	0.008153
0.4125	0.624789	0.0125	0.76625	0.059684	0.025432
0.43	0.692754	0.007155	0.80875	0.026746	0.055421
0.4475	0.763318	0.003486	0.85125	0.009788	0.100284
0.465	0.836418	0.001265	0.89375	0.002548	0.161902
0.4825	0.911996	0.000224	0.93625	0.00033	0.241966
0.5	0.99	0	0.97875	0.000004	0.342022
			1	0	0.4

Tabela D.2: Curvas de permeabilidade relativa das fácies 2 (média energia).

Sw	Krw	Krow	S1	Krg	Krog
0.15	0	0.6	0.15	1	0
0.1725	0.002	0.533231	0.1925	0.915	0
0.195	0.008	0.470879	0.235	0.83	0
0.2175	0.018	0.412871	0.2775	0.745	0
0.24	0.032	0.359135	0.32	0.66	0
0.2625	0.05	0.309594	0.3625	0.575	0
0.285	0.072	0.264166	0.405	0.49	0
0.3075	0.098	0.222768	0.4475	0.405	0
0.33	0.128	0.18531	0.49	0.32	0
0.3525	0.162	0.1517	0.5325	0.235	0
0.375	0.2	0.121838	0.55375	0.193416	0.00001
0.3975	0.242	0.095618	0.59625	0.129607	0.003203
0.42	0.288	0.072927	0.63875	0.083064	0.01434
0.4425	0.338	0.053642	0.68125	0.050348	0.035269
0.465	0.392	0.03763	0.72375	0.028405	0.067234
0.4875	0.45	0.024741	0.76625	0.014561	0.111215
0.51	0.512	0.014809	0.80875	0.006525	0.16803
0.5325	0.578	0.007641	0.85125	0.002388	0.238394
0.555	0.648	0.003007	0.89375	0.000622	0.322939
0.5775	0.722	0.000611	0.93625	0.000081	0.422241
0.6	0.8	0	0.97875	0.000001	0.536824
			1	0	0.6

Tabela D.3: Curvas de permeabilidade relativa das fácies 3 (alta energia).

Sw	Krw	Krow	Sl	Krg	Krog
0.15	0	0.8	0.15	1	0
0.1775	0.00005	0.722	0.1925	0.8725	0
0.205	0.0004	0.648	0.235	0.745	0
0.2325	0.00135	0.578	0.2775	0.6175	0
0.26	0.0032	0.512	0.32	0.49	0
0.2875	0.00625	0.45	0.3625	0.3625	0
0.315	0.0108	0.392	0.405	0.235	0
0.3425	0.01715	0.338	0.4475	0.1075	0
0.37	0.0256	0.288	0.46875	0.087045	0.00093
0.3975	0.03645	0.242	0.51125	0.062359	0.009921
0.425	0.05	0.2	0.55375	0.043337	0.028467
0.4525	0.06655	0.162	0.59625	0.02904	0.056566
0.48	0.0864	0.128	0.63875	0.018611	0.094219
0.5075	0.10985	0.098	0.68125	0.011281	0.141426
0.535	0.1372	0.072	0.72375	0.006364	0.198186
0.5625	0.16875	0.05	0.76625	0.003263	0.2645
0.59	0.2048	0.032	0.80875	0.001462	0.340368
0.6175	0.24565	0.018	0.85125	0.000535	0.425789
0.645	0.2916	0.008	0.89375	0.000139	0.520764
0.6725	0.34295	0.002	0.93625	0.000018	0.625293
0.7	0.4	0	0.97875	0	0.739376
			1	0	0.8

E

Resultados do Ajuste de Histórico

E.1

Caso de Estudo 1A

As figuras E.1 a E.5 apresentam os resultados do processo de ajuste de histórico do caso de estudo 1A.

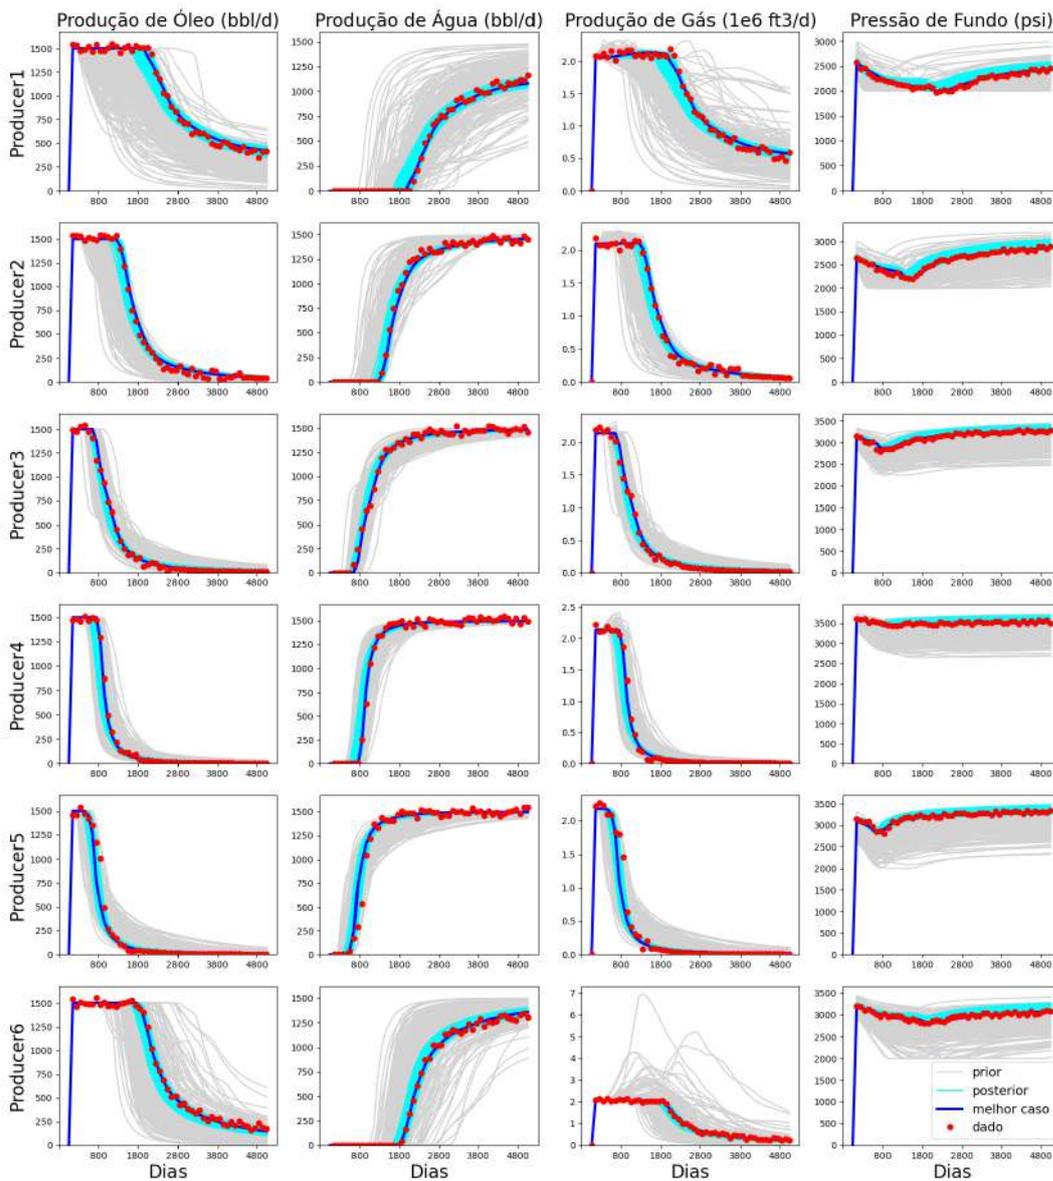
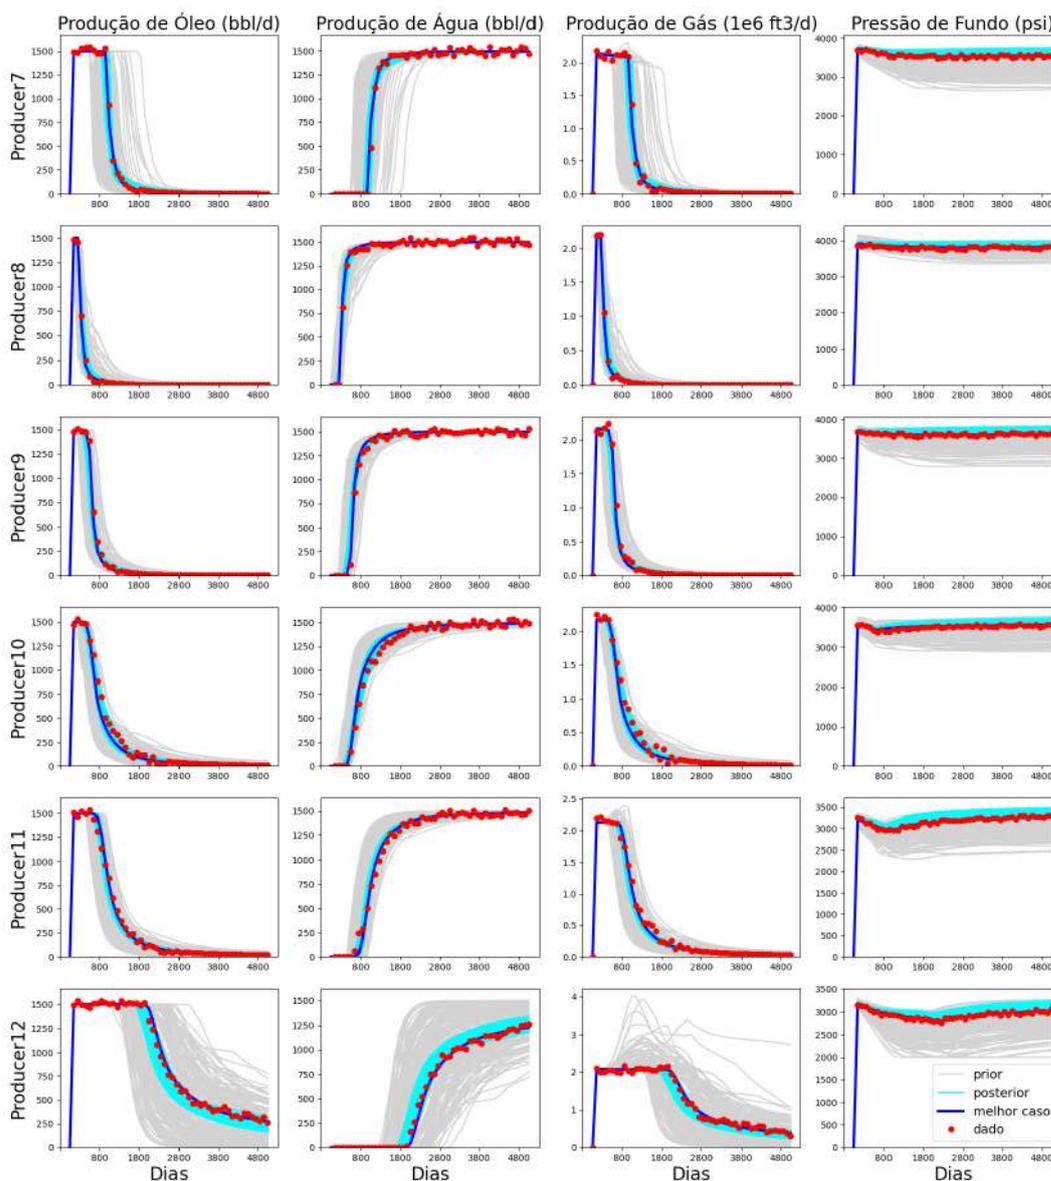


Figura E.1: Ajuste de histórico do **caso de estudo 1A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (1/4).



PUC-Rio - Certificação Digital N° 2020961/CA

Figura E.2: Ajuste de histórico do **caso de estudo 1A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (2/4).

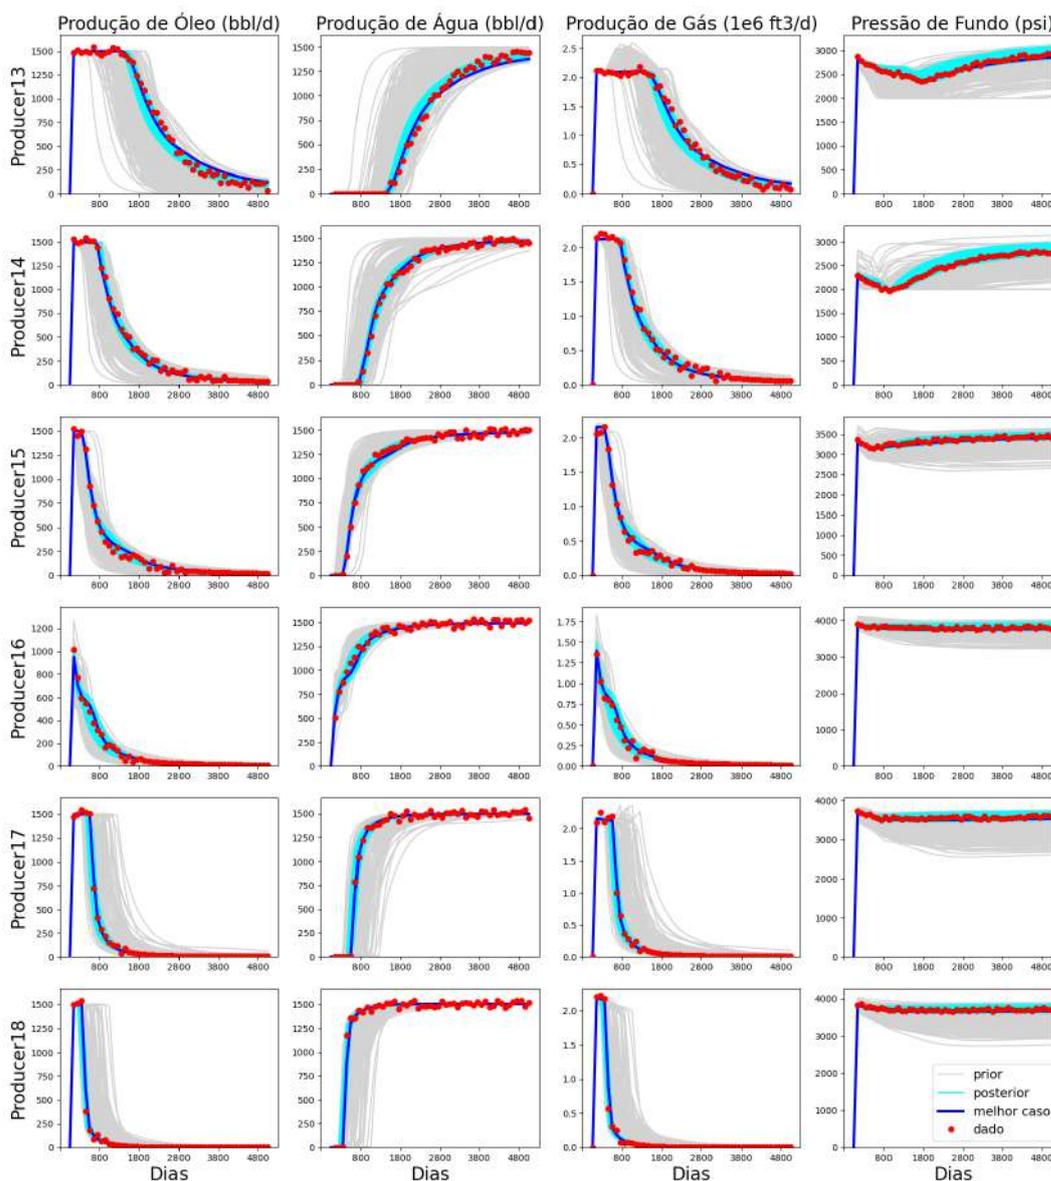
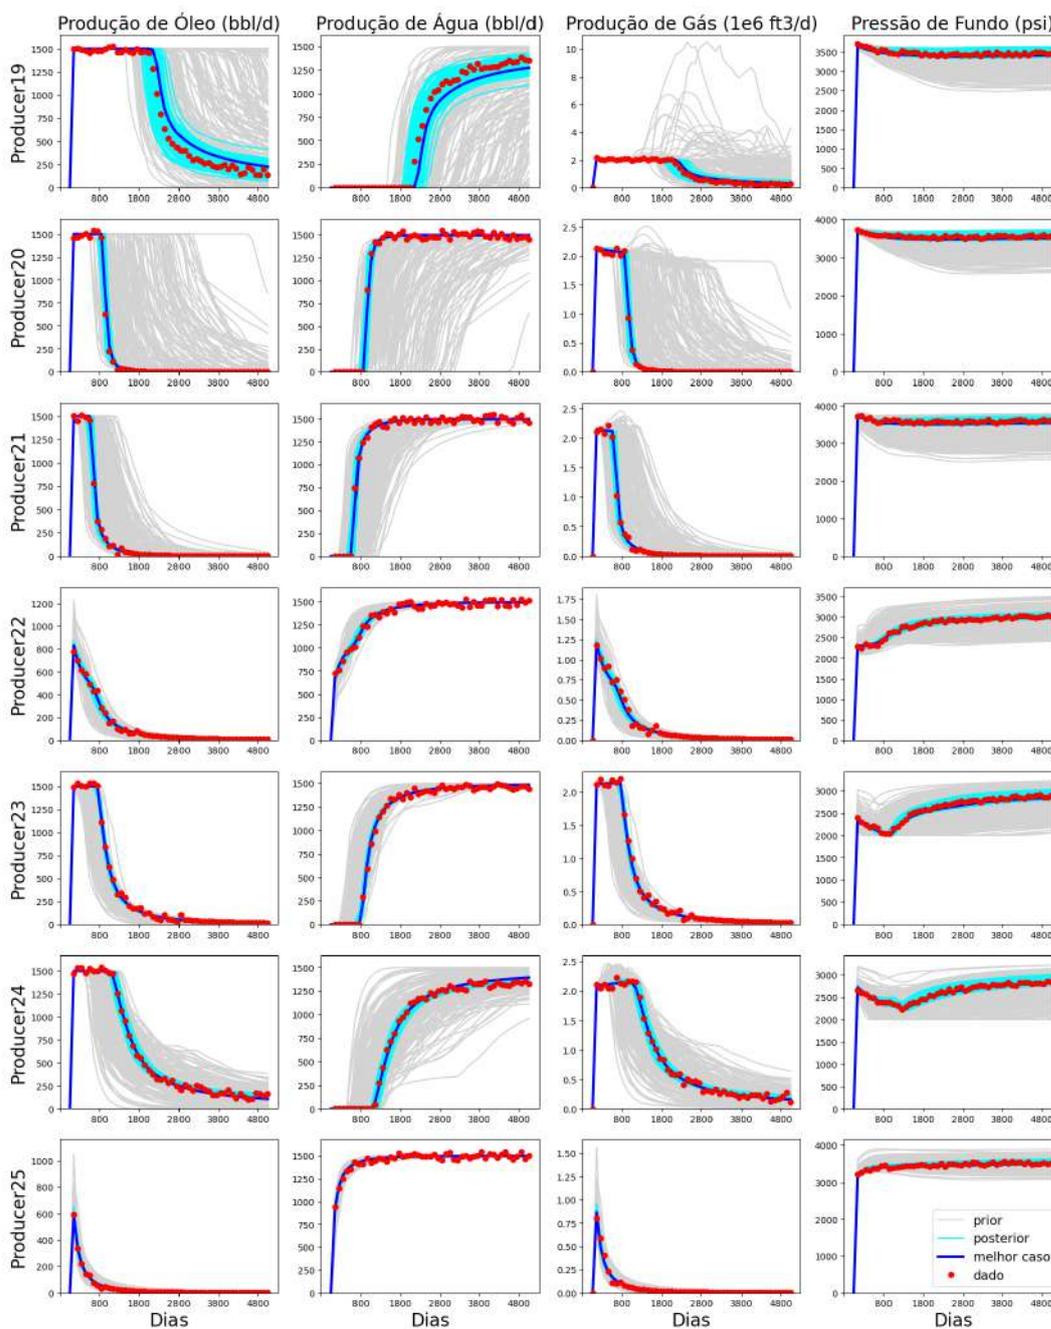


Figura E.3: Ajuste de histórico do **caso de estudo 1A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (3/4).



PUC-Rio - Certificação Digital N° 2020961/CA

Figura E.4: Ajuste de histórico do **caso de estudo 1A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (4/4).

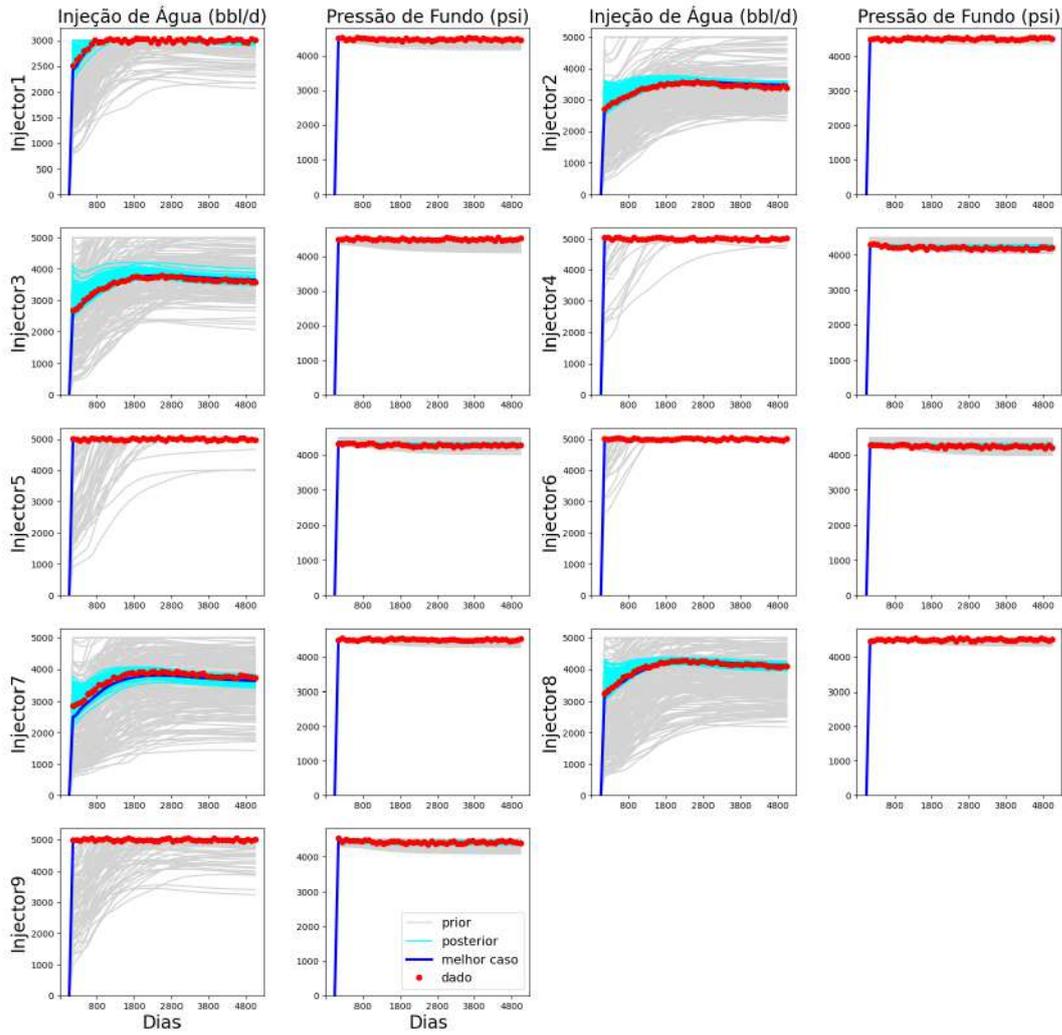


Figura E.5: Ajuste de histórico do **caso de estudo 1A**, com cada coluna representando um tipo de dado e cada linha representando dois poços **injetores**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste.

E.2

Caso de Estudo 1B

As figuras E.6 a E.10 apresentam os resultados do processo de ajuste de histórico do caso de estudo 1B.

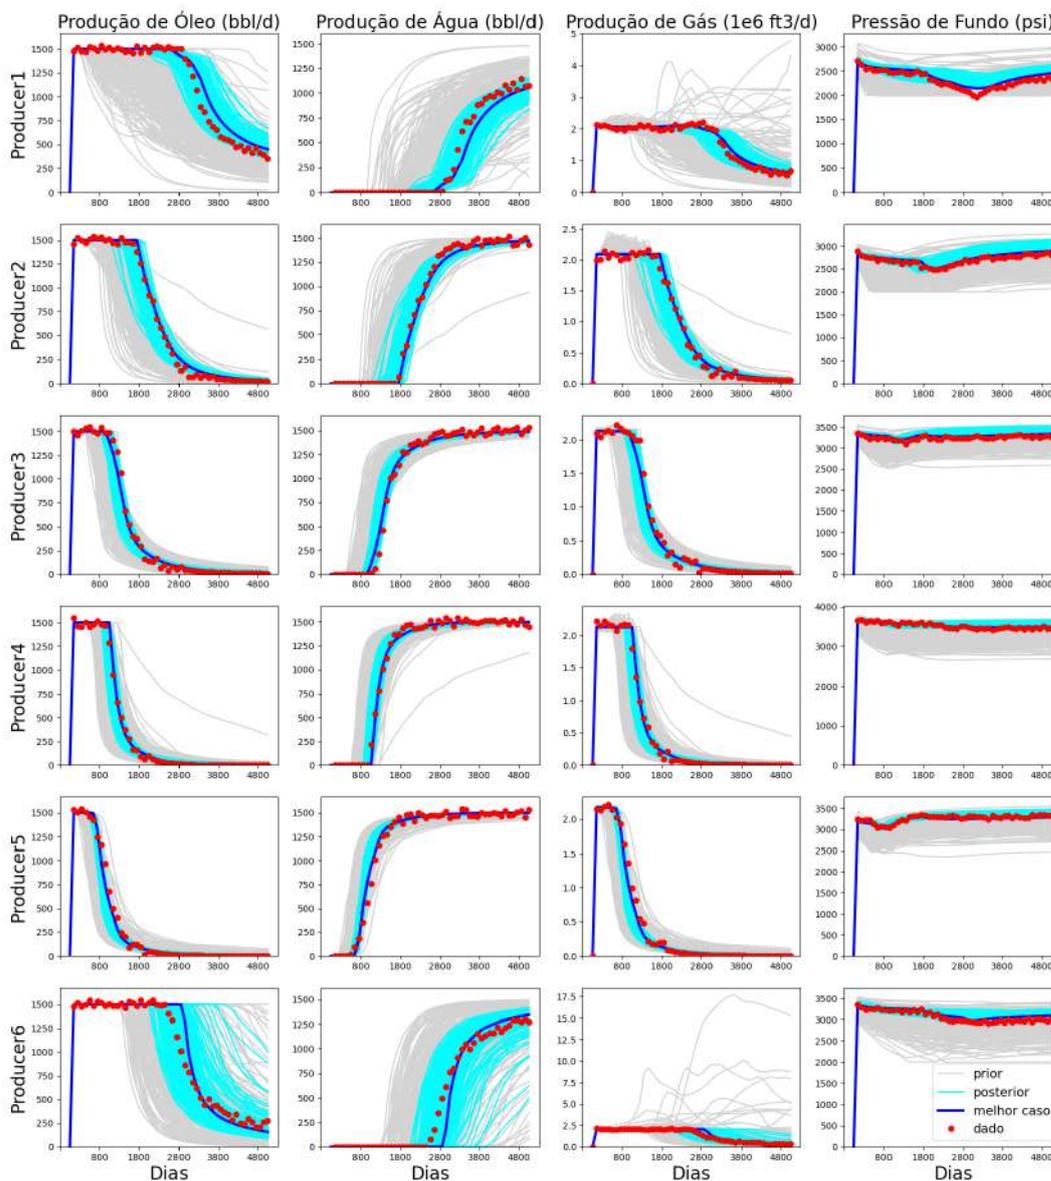
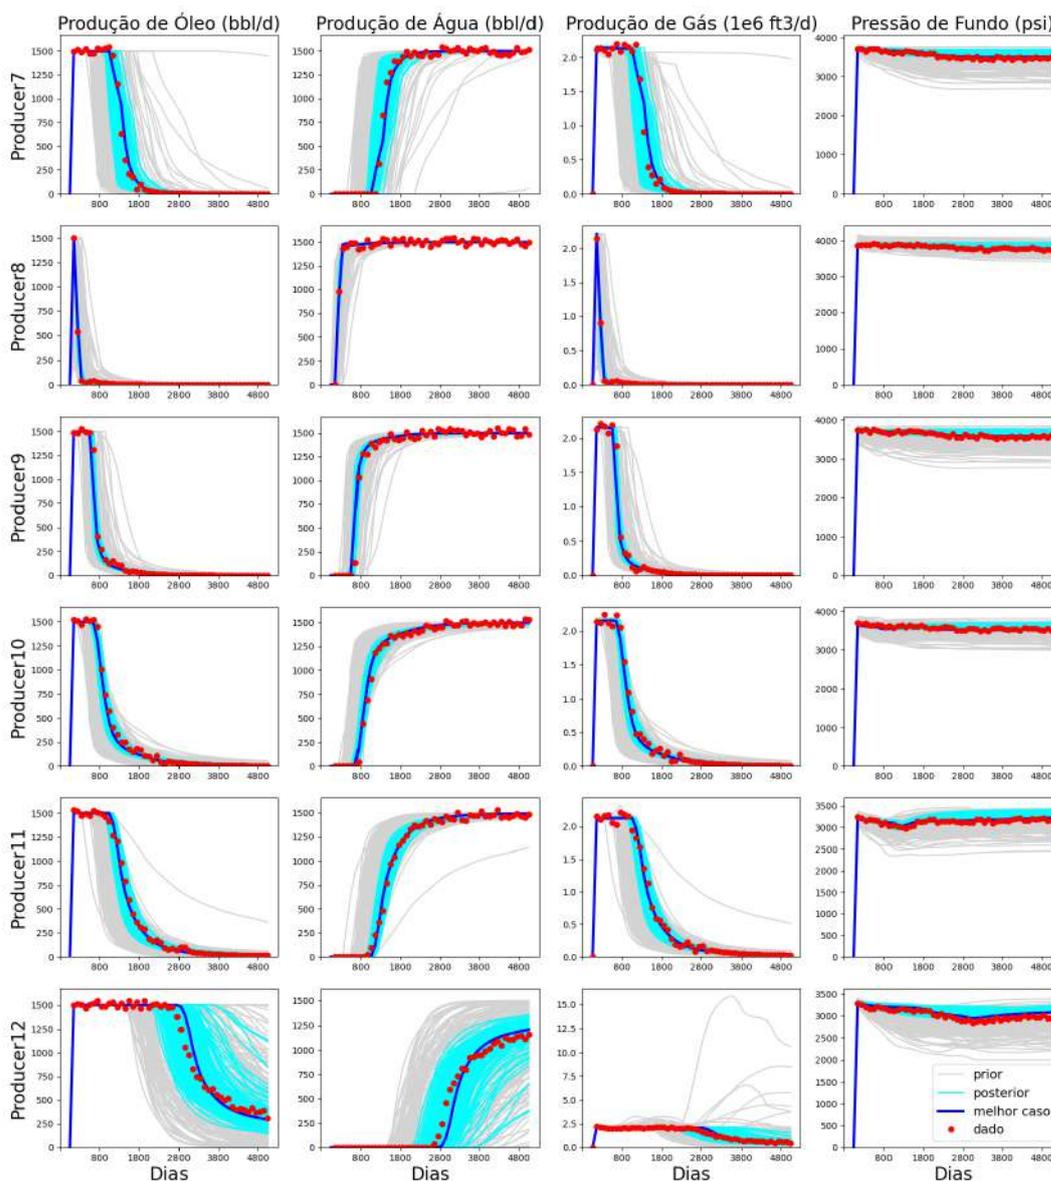


Figura E.6: Ajuste de histórico do **caso de estudo 1B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (1/4).



PUC-Rio - Certificação Digital N° 2020961/CA

Figura E.7: Ajuste de histórico do **caso de estudo 1B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (2/4).

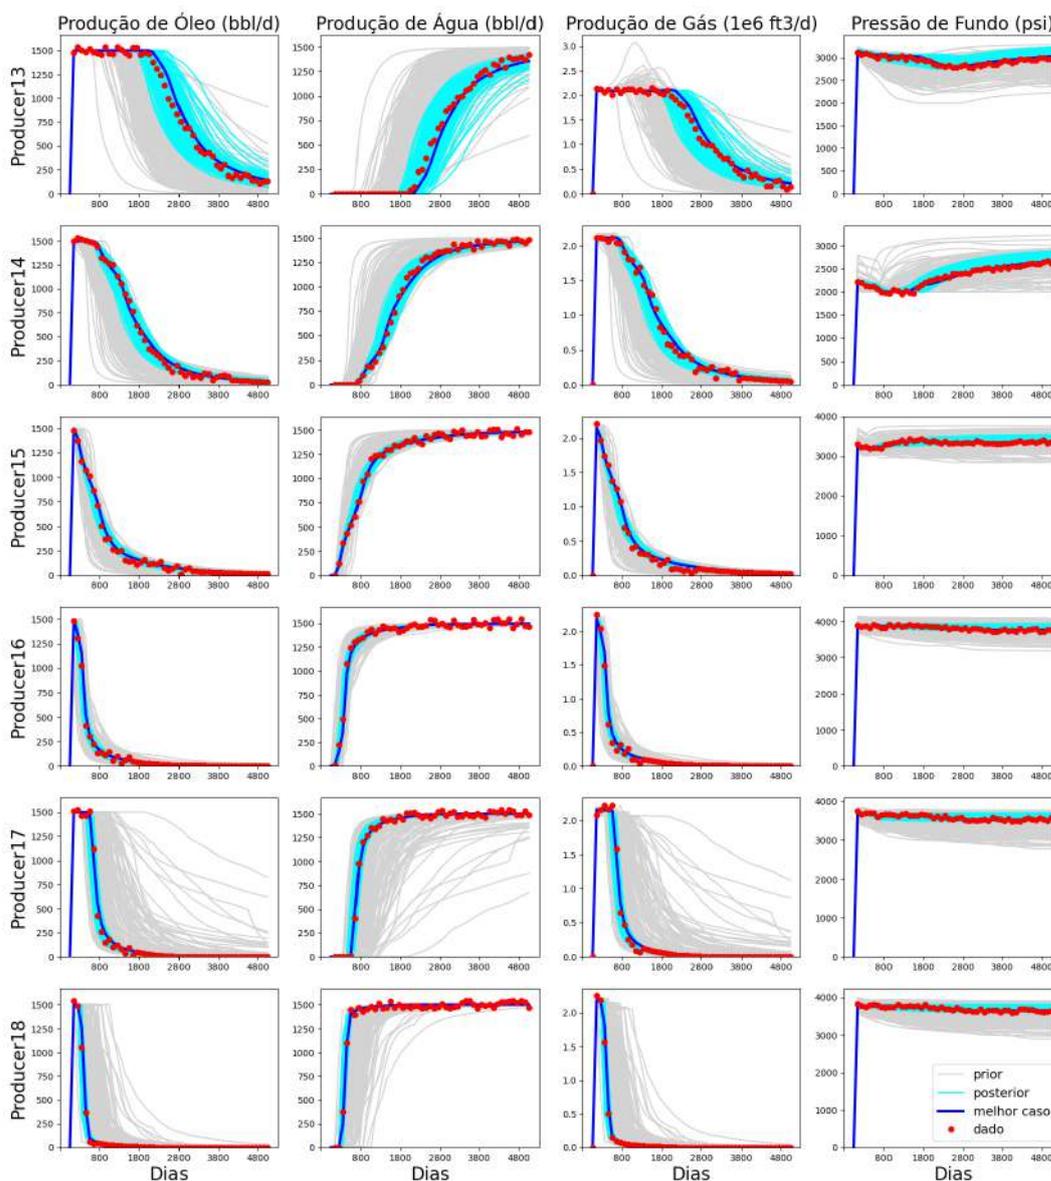
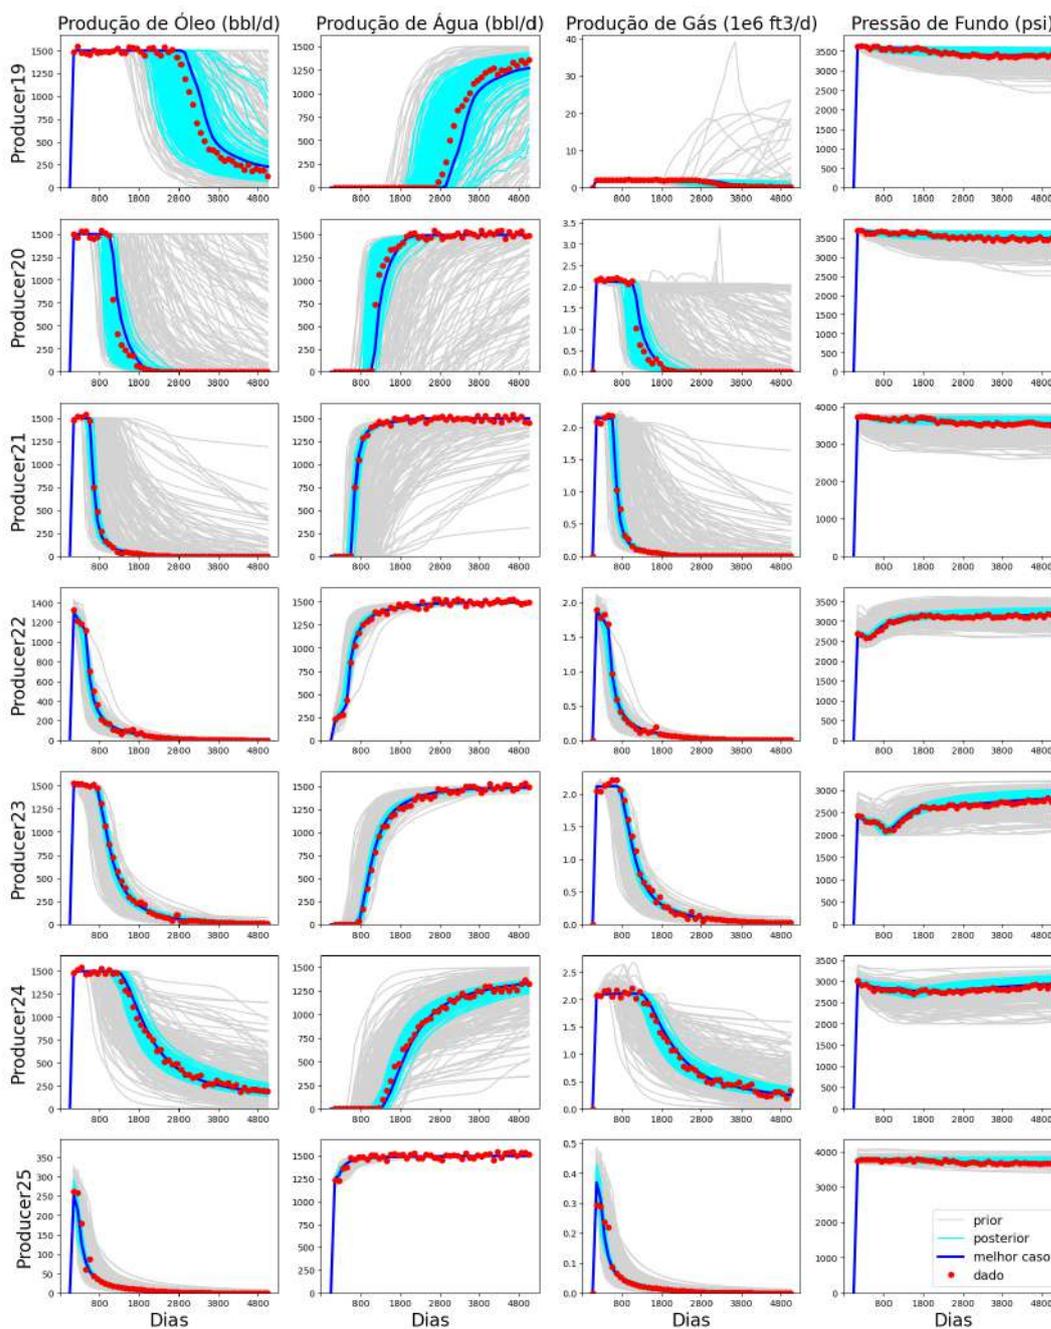


Figura E.8: Ajuste de histórico do **caso de estudo 1B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (3/4).



PUC-Rio - Certificação Digital Nº 2020961/CA

Figura E.9: Ajuste de histórico do **caso de estudo 1B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (4/4).

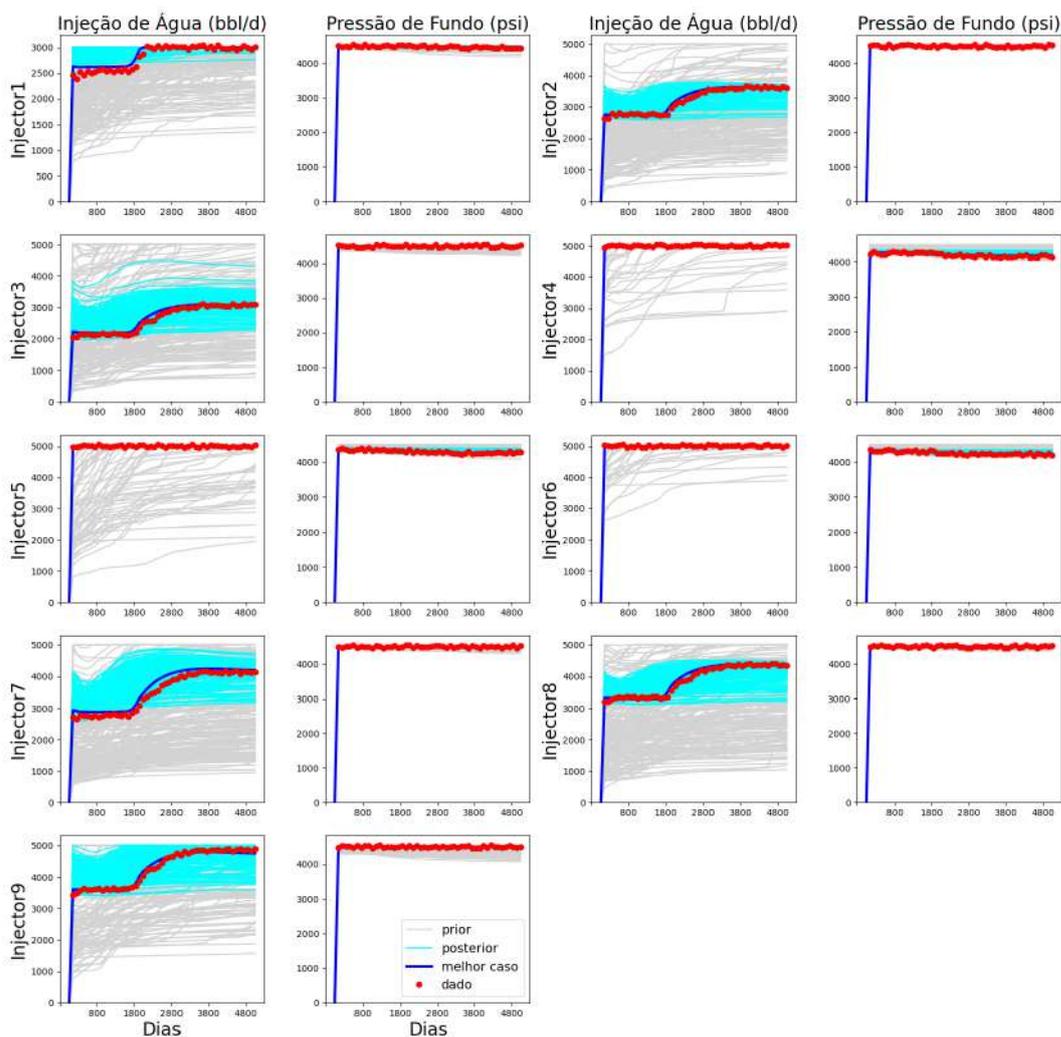


Figura E.10: Ajuste de histórico do **caso de estudo 1B**, com cada coluna representando um tipo de dado e cada linha representando dois poços **injetores**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste.

E.3

Caso de Estudo 2A

As figuras E.11 a E.15 apresentam os resultados do processo de ajuste de histórico do caso de estudo 2A.

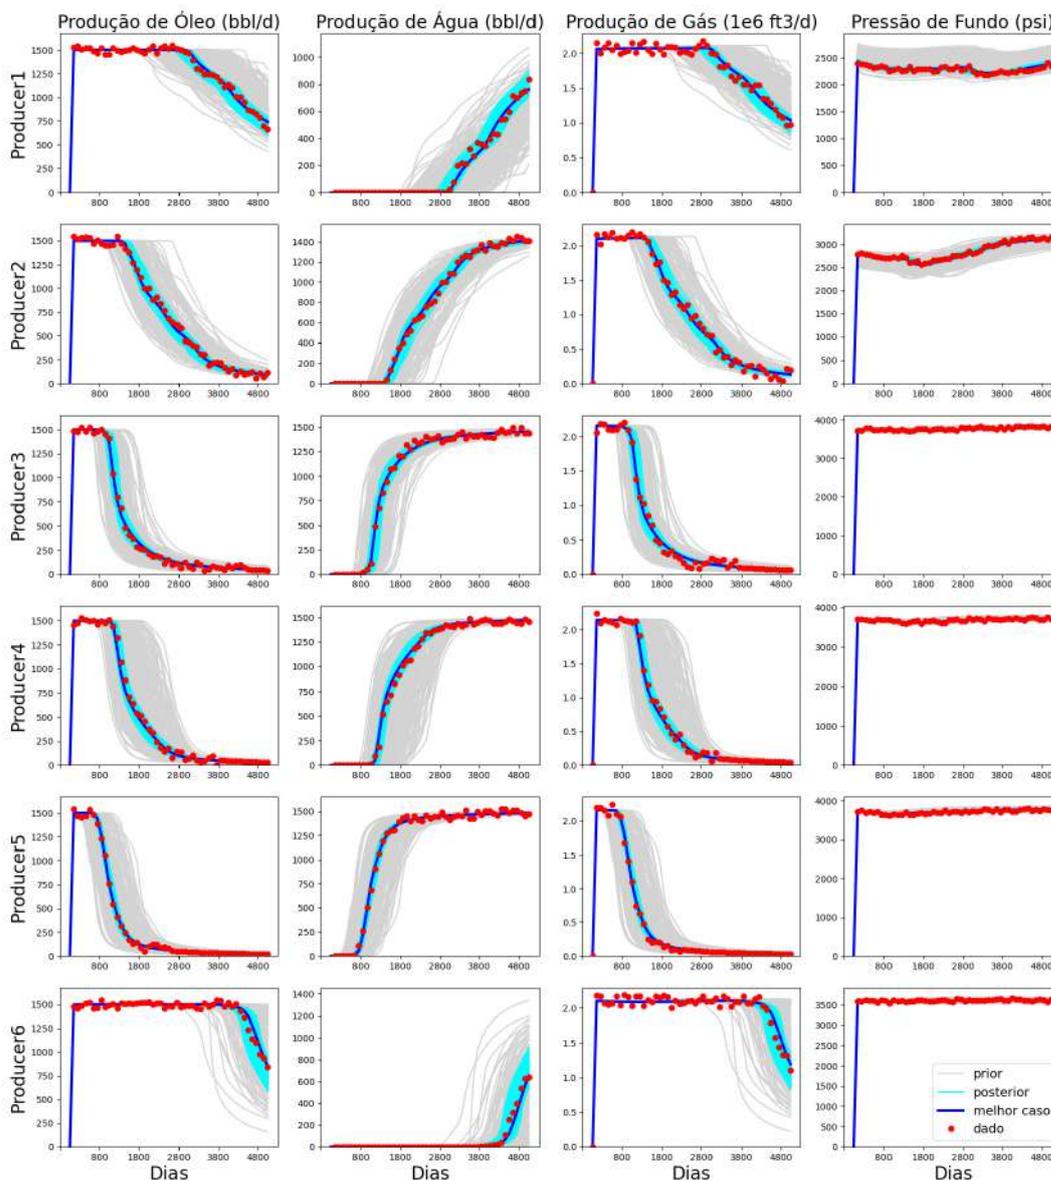


Figura E.11: Ajuste de histórico do **caso de estudo 2A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (1/4).

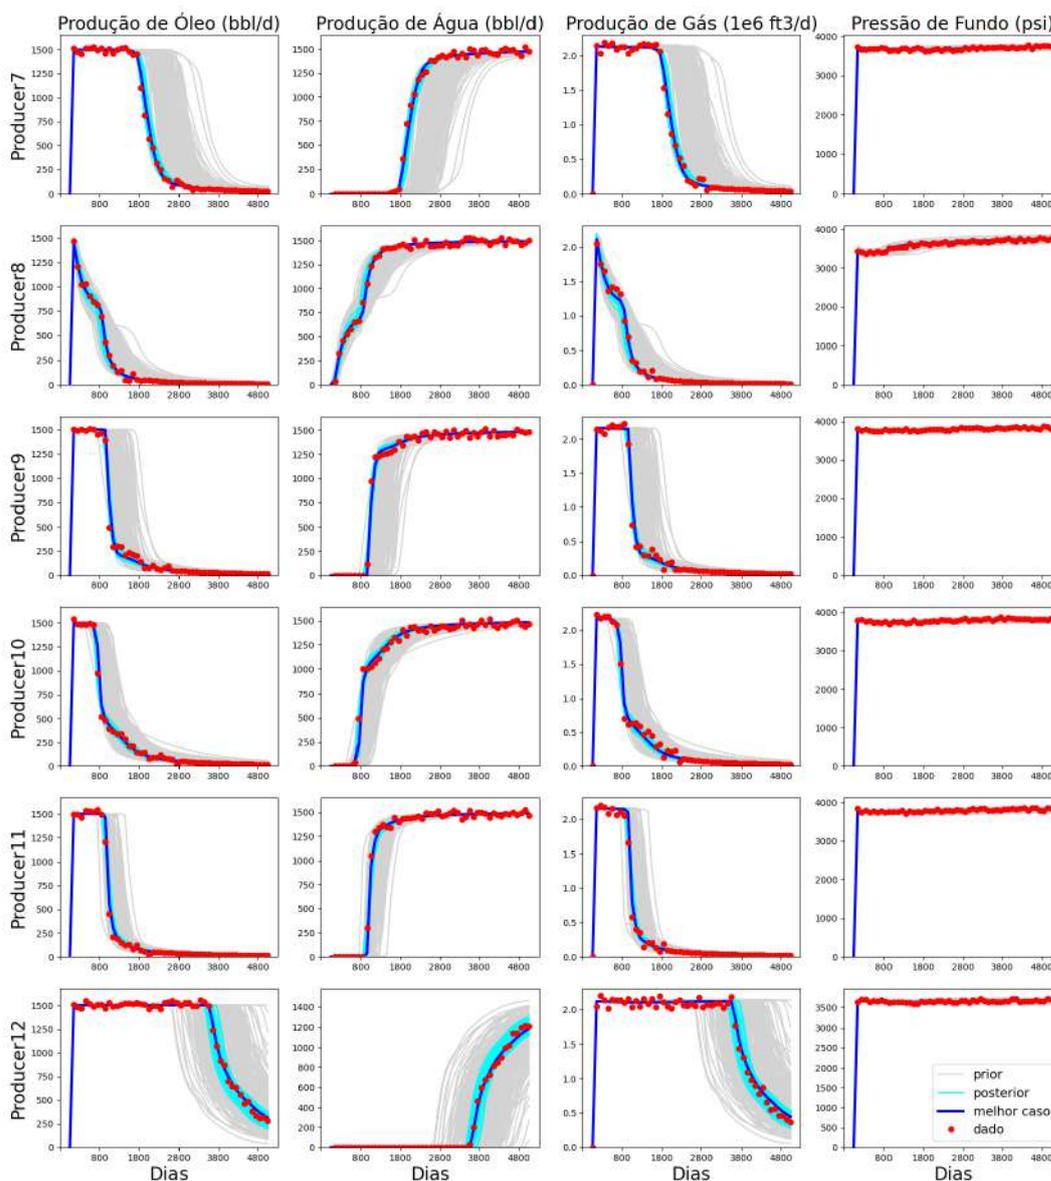


Figura E.12: Ajuste de histórico do **caso de estudo 2A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (2/4).

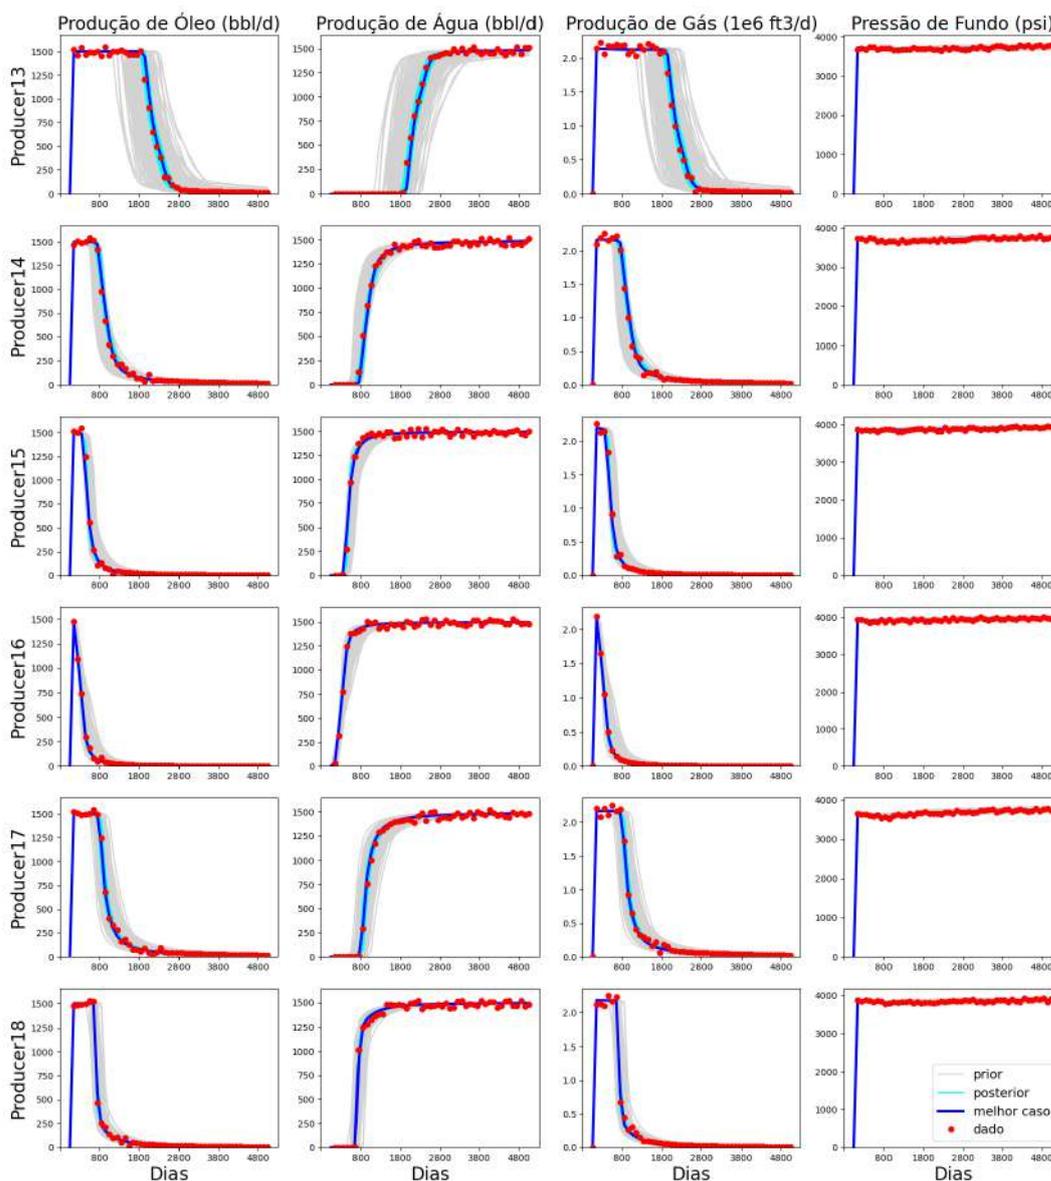


Figura E.13: Ajuste de histórico do **caso de estudo 2A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (3/4).

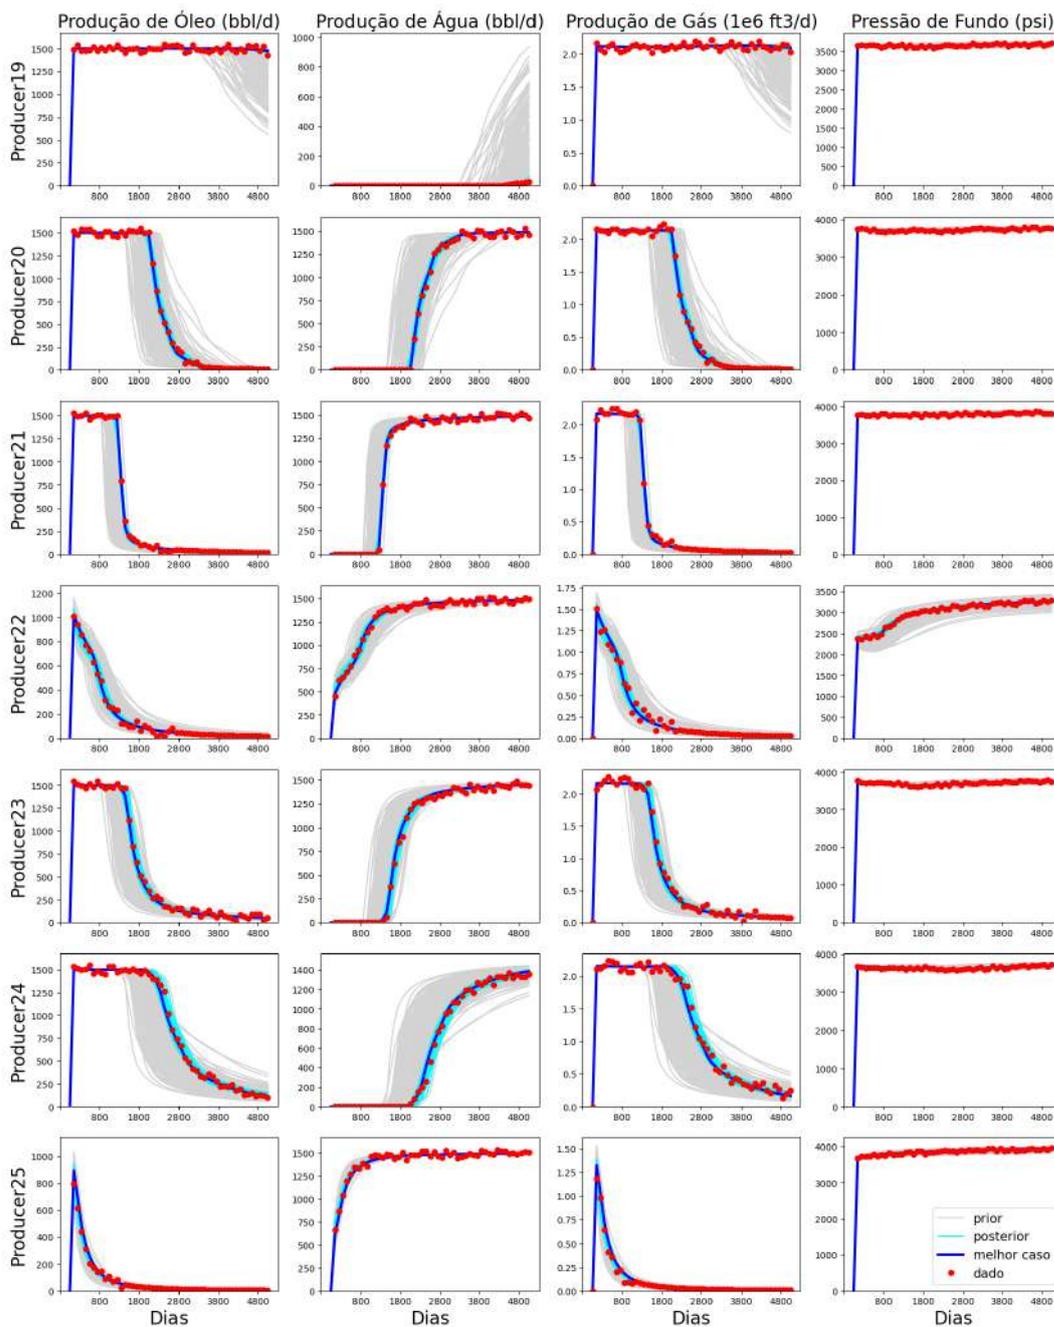


Figura E.14: Ajuste de histórico do **caso de estudo 2A**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (4/4).

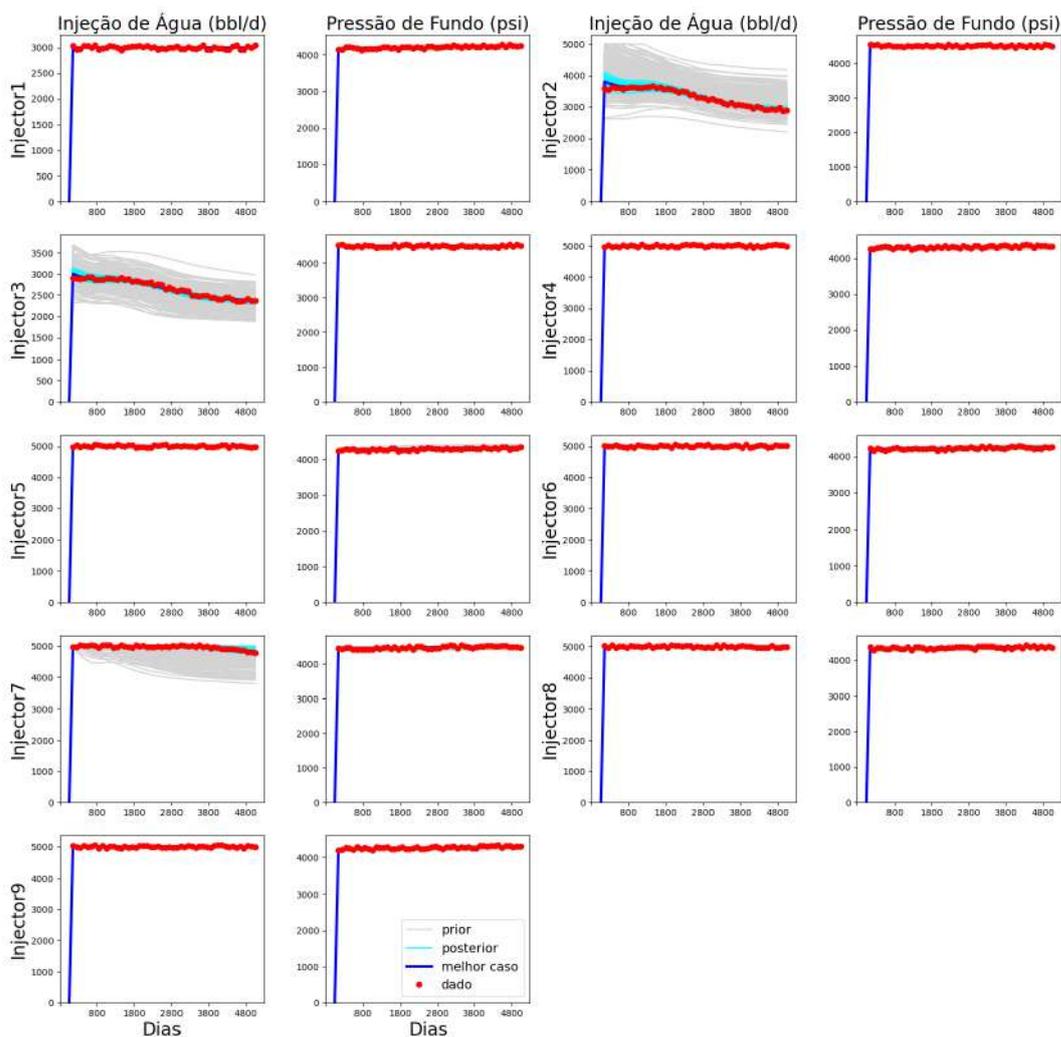


Figura E.15: Ajuste de histórico do **caso de estudo 2A**, com cada coluna representando um tipo de dado e cada linha representando dois poços **injetores**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste.

E.4 Caso de Estudo 2B

As figuras E.16 a E.20 apresentam os resultados do processo de ajuste de histórico do caso de estudo 2B.

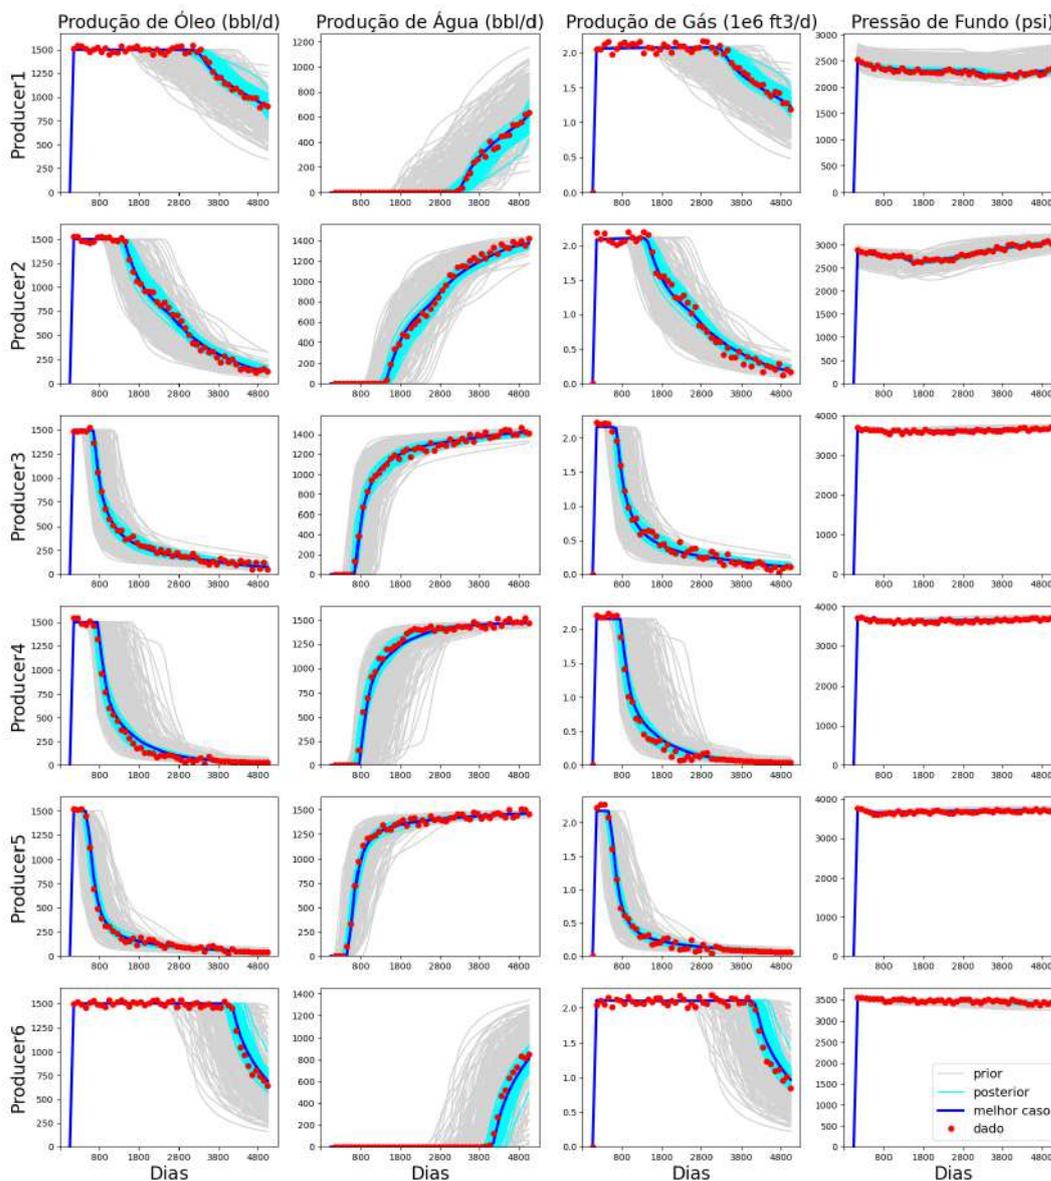


Figura E.16: Ajuste de histórico do **caso de estudo 2B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (1/4).

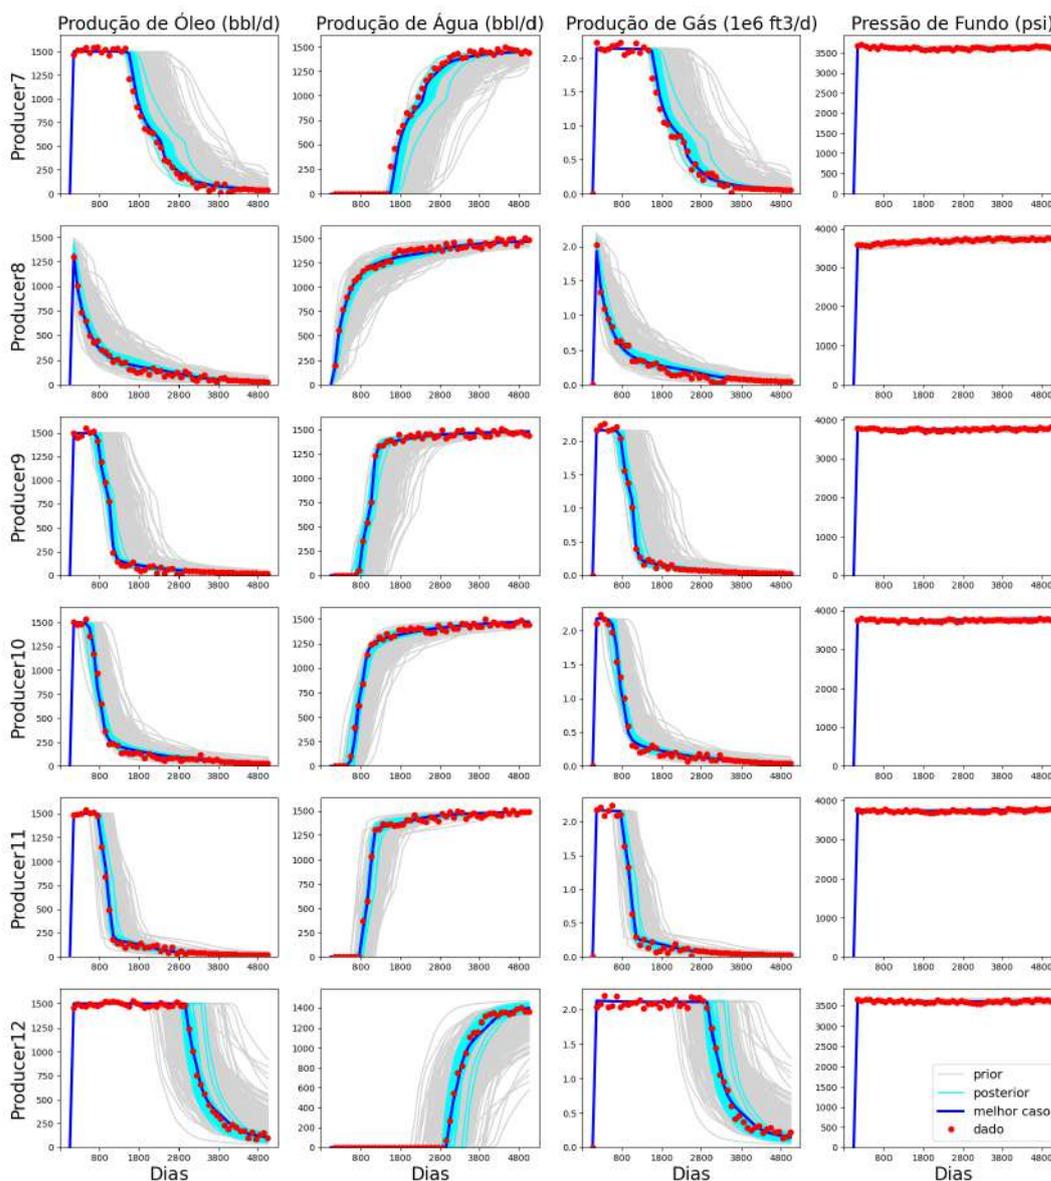


Figura E.17: Ajuste de histórico do **caso de estudo 2B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (2/4).

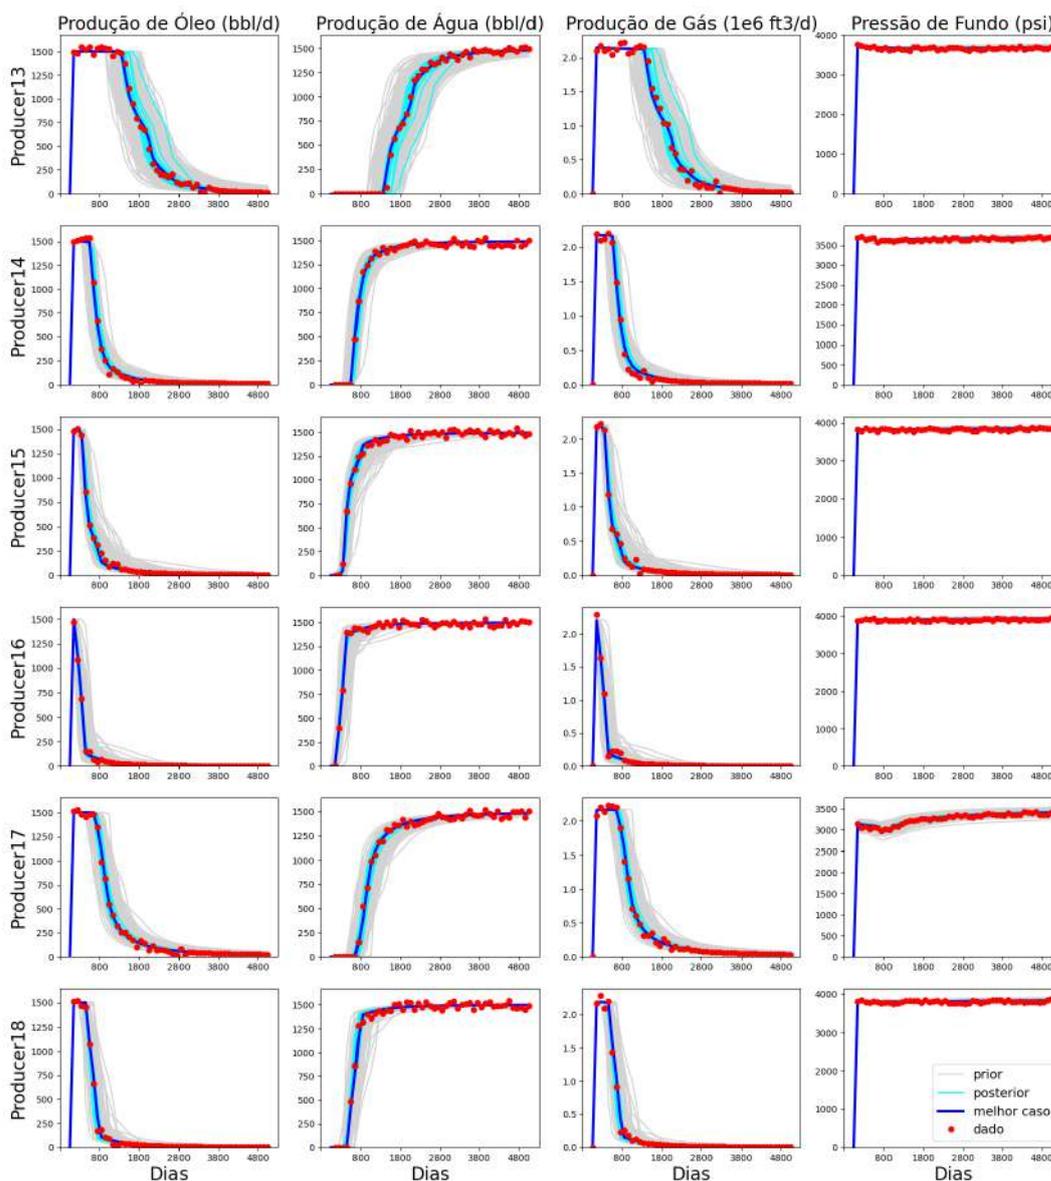
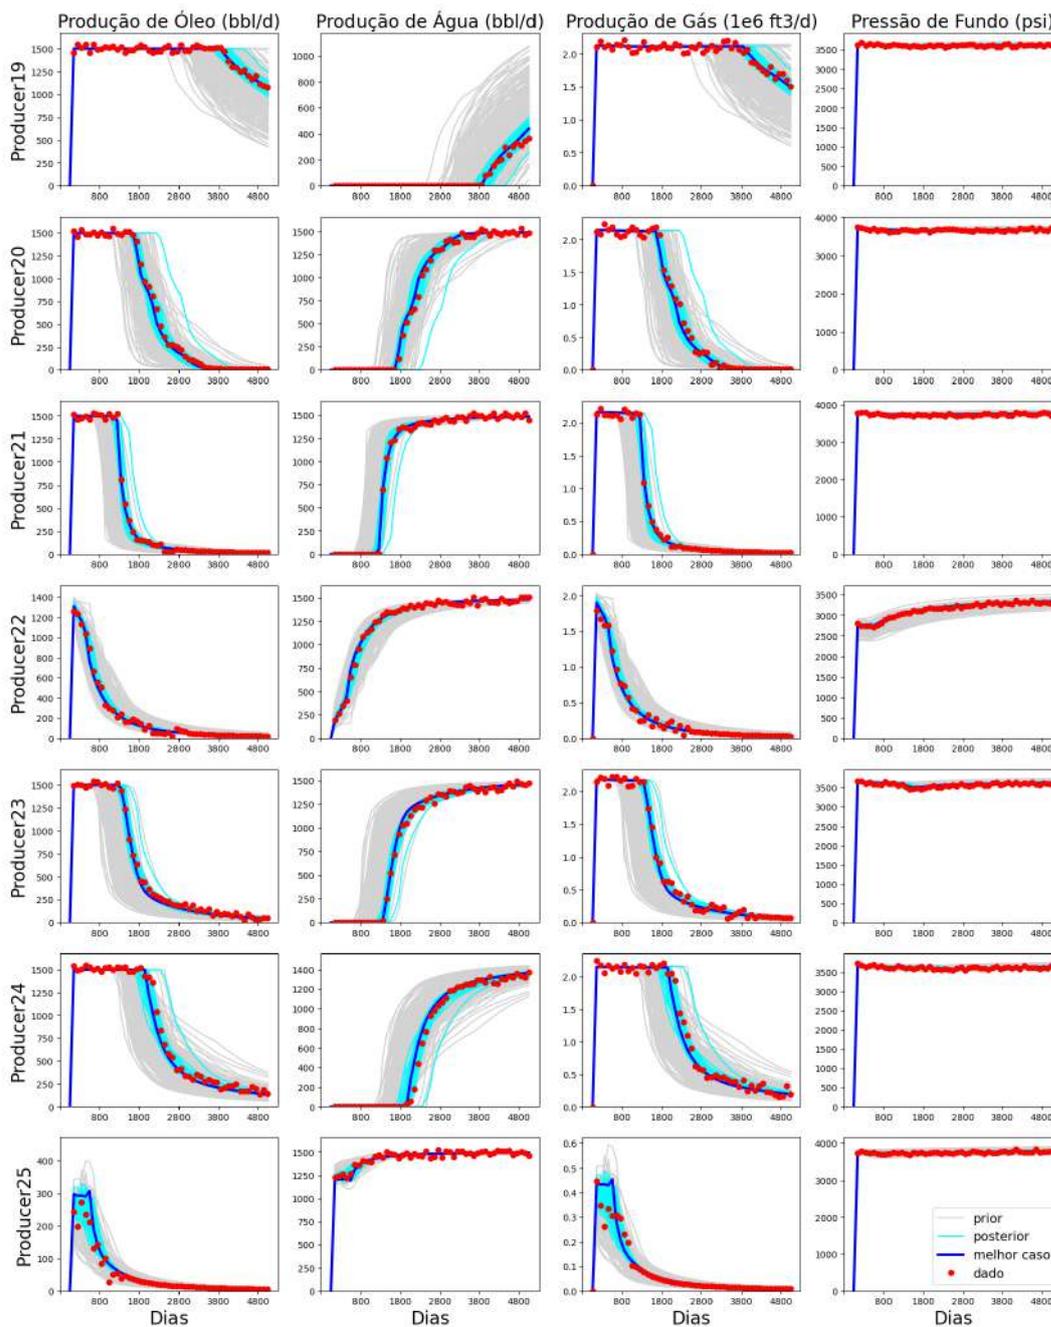


Figura E.18: Ajuste de histórico do **caso de estudo 2B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (3/4).



PUC-Rio - Certificação Digital N° 2020961/CA

Figura E.19: Ajuste de histórico do **caso de estudo 2B**, com cada coluna representando um tipo de dado e cada linha representando um poço **produtor**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste (4/4).

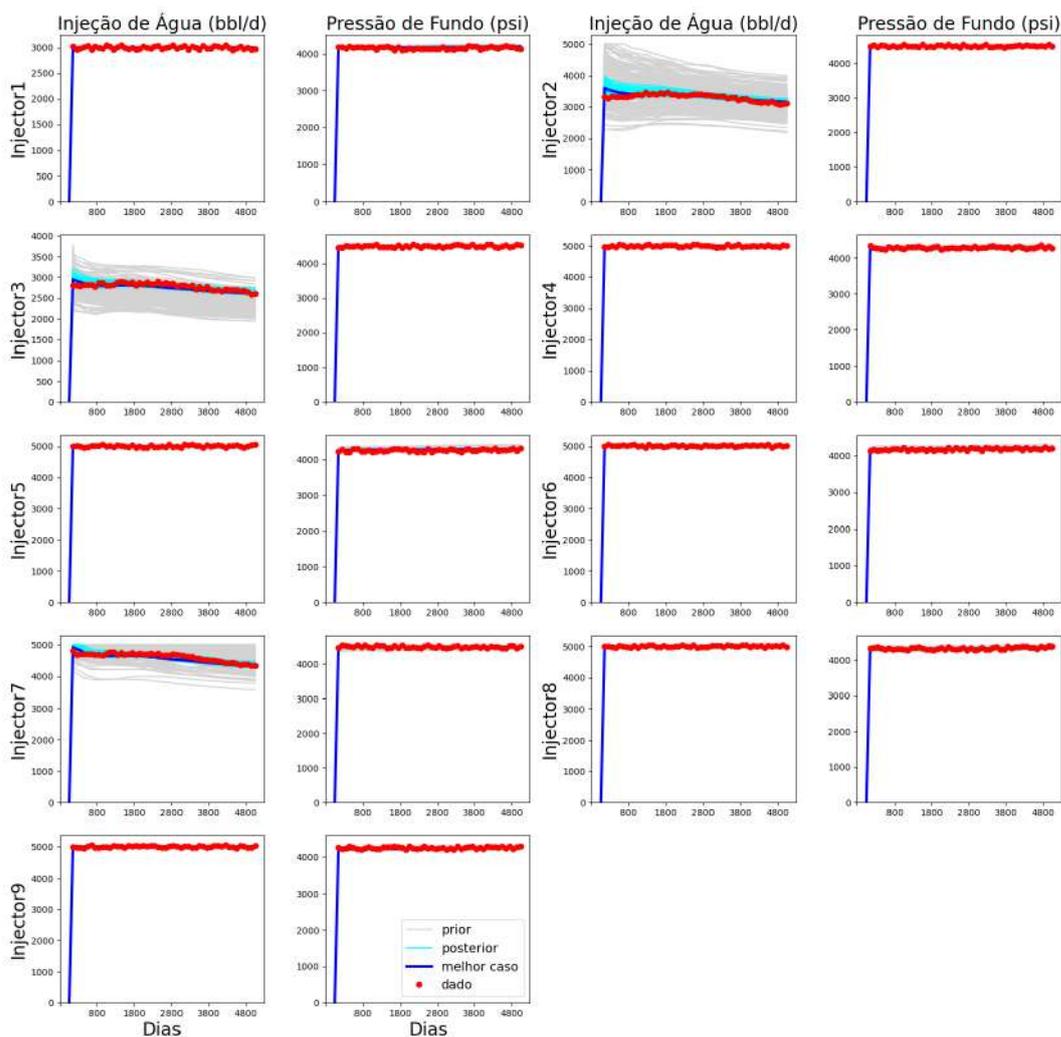


Figura E.20: Ajuste de histórico do **caso de estudo 2B**, com cada coluna representando um tipo de dado e cada linha representando dois poços **injetores**: em vermelho são apresentados os dados observados, em cinza o conjunto de modelos *a priori*, em ciano o conjunto de modelos *a posteriori* e em azul escuro a curva do modelo com melhor ajuste.