



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS REITOR JOÃO DAVID FERREIRA LIMA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO

Rodrigo Exterkoetter

**REDES NEURAIIS PROFUNDAS COM ENSEMBLE SMOOTHER APLICADOS NA
CARACTERIZAÇÃO DE RESERVATÓRIOS**

Florianópolis, Santa Catarina – Brasil
2024

Rodrigo Exterkoetter

**REDES NEURAIIS PROFUNDAS COM ENSEMBLE SMOOTHER APLICADOS NA
CARACTERIZAÇÃO DE RESERVATÓRIOS**

Tese submetido ao Programa de Pós-Graduação em Ciências da Computação da Universidade Federal de Santa Catarina para a obtenção do título de Doutor em Ciências da Computação.

Orientador(a): Mauro Roisenberg, Dr.

Florianópolis, Santa Catarina – Brasil

2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Exterkoetter, Rodrigo

Redes Neurais Profundas com Ensemble Smoother Aplicados na Caracterização de Reservatórios / Rodrigo Exterkoetter ; orientador, Mauro Roisenberg, 2024.

94 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Ciência da Computação, Florianópolis, 2024.

Inclui referências.

1. Ciência da Computação. 2. Deep Learning. 3. Ensemble Smoother. 4. Problemas Inversos. I. Roisenberg, Mauro. II. Universidade Federal de Santa Catarina. Programa de Pós Graduação em Ciência da Computação. III. Título.

Rodrigo Exterkoetter

Redes Neurais Profundas com Ensemble Smoother Aplicados na Caracterização de Reservatórios

O presente trabalho em nível de foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Rafael de Santiago, Dr.
Universidade Federal de Santa Catarina (UFSC)

Prof. Daniel Santana de Freitas, Dr.
Universidade Federal de Santa Catarina (UFSC)

Alexandre Anozé Emerick, Dr.
Petrobras

Smith Washington Arauco Canchumuni, Dr.
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de Doutor em Ciências da Computação.

Coordenação do Programa de
Pós-Graduação em Ciência da
Computação

Prof. Mauro Roisenberg, Dr.
Orientador(a)

Florianópolis, Santa Catarina – Brasil, 2024.

Este trabalho é dedicado em memória das minhas
amadas filhas, Cecília e Lilian, minhas estrelas
brilhantes, que me inspiram a seguir em frente com
força e determinação.

AGRADECIMENTOS

Agradeço à minha família pelo apoio incondicional e por sempre estarem ao meu lado em cada passo desta jornada.

À minha esposa, Bárbara Carminatti Ghiggi, por seu amor e companheirismo incansáveis, especialmente nos momentos mais desafiadores que enfrentamos juntos. Sou eternamente grato por você me presentear com nossas duas estrelinhas brilhantes, que hoje iluminam nossos corações e nossa vida.

Aos meus colegas, amigos e sócios Leandro Passos de Figueiredo e Fernando Luiz Bordignon, pela parceria e pela dedicação na construção do projeto da LTrace Geociências.

Ao professor e orientador Mauro Roisenberg, por me dar a oportunidade de integrar o L3C ainda no início da graduação, e por sua paciência, motivação e orientação ao longo desses 14 anos de colaboração, que culminaram na realização deste doutorado.

Aos coordenadores e amigos da Petrobras, Alexandre Emerick e Bruno Barbosa, pela interação durante os projetos de pesquisa, onde as ideias se concretizaram e formaram a base deste trabalho.

Por fim, meu sincero agradecimento a todos que, de alguma forma, contribuíram para a conclusão deste trabalho. Sem vocês, nada disso seria possível.

RESUMO

Na indústria de exploração de petróleo, a modelagem inversa de um reservatório visa prever um modelo geológico que represente com precisão a estrutura e os atributos das rochas do campo explorado. Em particular, o ajuste de histórico é utilizado para prever propriedades das rochas e atualizar o modelo do reservatório com base em novas informações adquiridas durante o ciclo produtivo. A inversão de fácies sísmicas, por sua vez, é empregada para estimar as fácies da subsuperfície a partir de dados sísmicos. No entanto, os dados sísmicos frequentemente apresentam grandes quantidades de dados redundantes e limitações de resolução, sendo necessária a estimativa de múltiplos cenários possíveis para um mesmo reservatório, o que leva a um desafio significativo devido ao elevado custo computacional. Atualmente, o Ensemble Smoother with Multiple Data Assimilation (ES-MDA) é amplamente aplicado a problemas inversos em geociências. Este método ajusta estocasticamente diversos modelos geológicos do reservatório com base em dados de produção e sísmicos. Contudo, o ES-MDA enfrenta limitações devido ao grande volume e redundância dos dados sísmicos, bem como à sua incapacidade de lidar diretamente com informações discretas e categóricas, além das premissas Gaussianas, que podem levar ao colapso ou a soluções insatisfatórias. Recentemente, técnicas de aprendizagem profunda e modelos generativos têm sido integrados com o ES-MDA para reduzir, reconstruir e gerar novos dados a partir de distribuições Gaussianas. O objetivo deste trabalho é integrar redes neurais profundas baseadas em arquiteturas totalmente convolucionais com o ES-MDA para reduzir a quantidade de informações dos dados sísmicos através da extração de características e representar as variáveis discretas em um espaço contínuo. Os resultados obtidos através dos experimentos mostra que a utilização de redes neurais profundas melhora significativamente a performance do processo de ajuste de histórico e inversão de fácies sísmicas com o ES-MDA, superando algumas das suas limitações presentes no estado da arte e com potencial de auxiliar profissionais de geociências na tomada de decisões em projetos de produção de petróleo.

Palavras-chaves: Redes Neurais Profundas. Ensemble Smoother. Problemas Inversos.

ABSTRACT

In the oil exploration industry, the inverse modeling of a reservoir aims to predict a geological model that represents the structure and attributes of rocks in the explored field. Specifically, history matching is used to obtain the reservoir model from new information during the production cycle. Seismic facies inversion, on the other hand, is used to predict rock properties based on subsurface facies from seismic and well data. However, the large amount of data and limitations in seismic data make the estimation of various possible scenarios for the same reservoir challenging and computationally demanding. Currently, the Ensemble Smoother with Multiple Data Assimilation (ES-MDA) is commonly applied to inverse problems in geosciences, where multiple geological reservoir models are stochastically estimated from production and seismic data. However, ES-MDA has some limitations due to the large amount of seismic data and its redundancies, along with the inability to use discrete and categorical information and Gaussian assumptions, which can cause ES-MDA to collapse or fail to estimate good solutions. Recently, deep learning techniques and generative models have been applied to reduce, reconstruct, and generate new data from Gaussian distributions. The objective of this work is to integrate deep neural networks based on fully convolutional layers with ES-MDA to reduce the seismic information to a reduced latent information through feature extraction and represent discrete variables in a continuous space. The results show that the use of deep neural networks can improve the performance of the history matching and seismic facies inversion process with ES-MDA, overcoming certain limitations of the method and assisting potential geoscience professionals in making decisions in oil production projects.

Keywords: Deep Learning. Ensemble Smoother. Inversion Problems.

LISTA DE FIGURAS

Figura 1	– Processo de aquisição da sísmica 4D.	15
Figura 2	– Ilustração das variáveis do problema inverso, modelo (esquerda) e dados (direita), para a caracterização e modelagem de reservatórios.	16
Figura 3	– Ilustração do problema direto e o problema inverso.	20
Figura 4	– Ilustração da integração de diversas fontes de dados para a caracterização de modelagem do reservatório.	23
Figura 5	– Ilustração do processo de ajuste de histórico com Sísmica 4D e dados de produção.	24
Figura 6	– Processo inverso do ajuste de histórico com as propriedades do reservatório (modelo) e dados (simulados e reais).	25
Figura 7	– Ilustração do processo de inversão de fácies sísmicas.	27
Figura 8	– Comparativo entre rede neural tradicional (esquerda) e rede neural profunda (direita).	31
Figura 9	– Representação de um rosto sorrindo (esquerda) e a representação em uma matriz de valores entre 0, para branco e 1, para preto (direita). Adaptado de Goodfellow, Bengio e Courville (2016).	33
Figura 10	– Exemplo de representação da matriz de parâmetros 3×3 chamada de <i>kernel</i> . Adaptado de Goodfellow, Bengio e Courville (2016).	33
Figura 11	– Ilustração do início da operação convolução (a) e o mapa de característica obtido ao final após mover o <i>kernel</i> por toda a imagem (b). Da esquerda para a direita: pesos da imagem de entrada, <i>kernel</i> e o mapa de características. Adaptado de Goodfellow, Bengio e Courville (2016)	34
Figura 12	– Exemplo de uma estrutura de uma Rede Neural Convolutacional. Adaptada de Albelwi e Mahmood (2017).	35
Figura 13	– Aplicação de n <i>kernels</i> de tamanho $k \times k \times 3$ em uma entrada de tamanho $w \times h \times 3$. O resultado são n mapas de características de tamanho $w \times h$	35
Figura 14	– Exemplo dos mapas de características obtidos a partir de diferentes <i>kernels</i> (GOODFELLOW; BENGIO; COURVILLE, 2016).	36
Figura 15	– Operação de Pooling utilizando a função de máximo. Adaptada de Exterkoetter <i>et al.</i> (2018).	37
Figura 16	– Exemplo de um modelo de Rede Neural do tipo Autoencoder.	38
Figura 17	– Exemplo de um Autoencoder Convolutacional (LONG; SHELHAMER; DARRELL, 2015).	38
Figura 18	– Exemplo de um Variational Autoencoder adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016).	40

Figura 19	–	Arquitetura das Redes Gerativas Adversárias. Adaptada de Goodfellow, Bengio e Courville (2016).	41
Figura 20	–	Método de transferência de aprendizado para reaproveitamento dos pesos das camadas convolucionais para outro domínio de problema e treinando somente as camadas totalmente conectadas.	42
Figura 21	–	Autoencoder convolucional utilizado para redução da sísmica 4D. Adaptado de Liu e Grana (2020).	45
Figura 22	–	Variational Autoencoder com camadas convolucionais utilizada no trabalho de Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019).	47
Figura 23	–	Etapa de treinamento e o espaço latente da VAE para cinco realizações de fácies do conjunto de validação. Adaptada de Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019).	48
Figura 24	–	Proposta deste trabalho para ajuste de histórico com ES-MDA integrado com Autoencoder como um extrator de características dos dados observados e simulados.	54
Figura 25	–	Treinamento para geração de fácies utilizando VAE.	57
Figura 26	–	Treinamento para geração de fácies utilizando GANs.	58
Figura 27	–	Proposta deste trabalho para a integração do ES-MDA com redes generativas para inversão de fácies sísmicas.	59
Figura 28	–	Exemplo de imagens do conjunto de dados COCO 2017.	62
Figura 29	–	Autoencoder 2D proposta neste trabalho no processo de reconstrução de imagens com a entrada (esquerda), latente (centro) e saída reconstruída (direita).	63
Figura 30	–	Exemplo de volumes do conjunto de dados MNIST 3D.	63
Figura 31	–	Modelo de reservatório PUNQ-S3 (FLORIS <i>et al.</i> , 2001).	65
Figura 32	–	Resultados para a reconstrução da sísmica 4D com ajuste fino do Autoencoder.	67
Figura 33	–	Resultados na alteração de um ponto do espaço latente para as características extraídas através do Autoencoder totalmente convolucional.	68
Figura 34	–	Resultados comparando a referência e utilizando ES-MDA, ES-MDA com Autoencoder 2D e Autoencoder 3D.	69
Figura 35	–	Função objetiva computada durante o processo de assimilação com ES-MDA e ES-MDA integrado com Autoencoder 2D e 3D.	70
Figura 36	–	Histograma do valor da função objetiva computada para cada membro do ensemble durante o processo de assimilação com ES-MDA e ES-MDA integrado com Autoencoder 2D e 3D.	70
Figura 37	–	Resultado para o caso Fake 3D com ES-MDA e ES-MDA integrado com Autoencoder 3D.	71

Figura 38	– Matrizes de transição utilizadas para gerar amostras de fácies de um reservatório carbonático do pré-sal. Adaptada de Figueiredo, Rodrigues <i>et al.</i> (2019)	72
Figura 39	– Exemplos de amostras de fácies geradas a partir da cadeia de Markov utilizando P_v e P_h	73
Figura 40	– Função de erro durante o treinamento da VAE e VAE totalmente convolucional proposta neste trabalho.	73
Figura 41	– Exemplos de fácies geradas, a partir de amostras Gaussianas inseridas no espaço latente (a), utilizando o decoder correspondente da VAE (b) e FCVAE (c).	74
Figura 42	– Função de erro durante o treinamento da GAN e GAN totalmente convolucional propostas neste trabalho.	75
Figura 43	– Exemplos de fácies geradas, a partir de amostras Gaussianas inseridas no espaço latente (a), utilizando a estrutura geradora correspondente da GAN (b) e FCGAN (c).	76
Figura 44	– Modelo de fácies de referência utilizada nos experimentos para reparametrização das fácies com redes generativas.	76
Figura 45	– Geração do ensemble inicial a partir de amostras gaussianas. . .	78
Figura 46	– Resultado obtidos com ES-MDA e a reparametrização das fácies com VAE, onde (a) é o modelo de referência, (b) o início do processo de inversão e (c) as fácies obtidas após 20 iterações. .	79
Figura 47	– Resultado obtidos com ES-MDA e a reparametrização das fácies com GAN, onde (a) é o modelo de referência, (b) o início do processo de inversão e (c) as fácies obtidas após 20 iterações. .	80
Figura 48	– Convergência do erro com ES-MDA-VAE e ES-MDA-FCVAE durante 20 iterações.	81
Figura 49	– Convergência do erro com ES-MDA-GAN e ES-MDA-FCGAN durante 20 iterações.	81
Figura 50	– Convergência do erro do ES-MDA-VAE, ES-MDA-FCVAE, ES-MDA-GAN e ES-MDA-FCGAN durante 20 iterações.	82

LISTA DE TABELAS

Tabela 1	– Autoencoder 2D proposta neste trabalho.	51
Tabela 2	– Autoencoder 3D proposta neste trabalho.	53
Tabela 3	– Comparação dos trabalhos relacionados com a proposta deste trabalho para ajuste de histórico com sísmica 4D.	55
Tabela 4	– Arquitetura da VAE utilizada nos experimentos deste trabalho. . .	56
Tabela 5	– Arquitetura da GAN utilizada nos experimentos deste trabalho. . .	57
Tabela 6	– Comparação dos trabalhos relacionados com a proposta deste trabalho para inversão de fácies sísmicas.	60

LISTA DE ABREVIATURAS E SIGLAS

AE	Redes Autoencoders
ES	Ensemble Smoother
ES-MDA	Ensemble Smoother with Multiple Data Assimilation
FCA	Autoencoders Totalmente Convolutacional
GAN	Generative Adversarial Net
FCGAN	Generative Adversarial Net Totalmente Convolutacional
RNA	Rede Neural Artificial
RNC	Rede Neural Convolutacional
RNG	Rede Neural Generativa
RNTC	Rede Neural Totalmente Convolutacional
VAE	Variational Autoencoder
FCVAE	Variational Autoencoder Totalmente Convolutacional

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVO GERAL	18
1.1.1	Pergunta de Pesquisa	18
1.1.2	Hipóteses	19
1.1.3	Objetivos Específicos	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	PROBLEMAS INVERSOS	20
2.2	CARACTERIZAÇÃO E MODELAGEM DE RESERVATÓRIOS	21
2.2.1	Ajuste de Histórico com Sísmica 4D	22
2.2.2	Inversão de Fácies Sísmicas	26
2.3	ENSEMBLE SMOOTHER WITH MULTIPLE DATA ASSIMILATION	27
2.3.1	Localização de Covariância	29
2.3.2	Aplicação e Desafios em Problemas Inversos	30
2.4	REDES NEURAIS PROFUNDAS	31
2.4.1	Redes Neurais Convolucionais	32
2.4.2	Autoencoders	37
2.4.3	Redes Neurais Generativas	38
2.4.3.1	Variational Autoencoder	39
2.4.3.2	Generative Adversarial Network	40
2.4.4	Transfer learning	41
3	TRABALHO RELACIONADOS	44
3.1	AJUSTE DE HISTÓRICO E ASSIMILAÇÃO DA SÍSMICA 4D	44
3.2	INVERSÃO DE FÁCIES SÍSMICAS	46
4	METODOLOGIA PROPOSTA	50
4.1	AUTOENCODER E ES-MDA PARA AJUSTE DE HISTÓRICO	50
4.1.1	Autoencoder 2D	50
4.1.2	Autoencoder 3D	52
4.1.3	Proposta para Ajuste de Histórico	52
4.2	REDES GENERATIVAS E ES-MDA PARA INVERSÃO DE FÁCIES SÍSMICAS	55
4.2.1	Variational Autoencoder	55
4.2.2	Generative Adversarial Net	56
4.2.3	Proposta para Inversão de Fácies Sísmicas	58
5	EXPERIMENTOS E RESULTADOS	61

5.1	AJUSTE DE HISTÓRICO E SÍSMICA 4D	61
5.1.1	Treinamento dos Autoencoders	61
5.1.1.1	Coco Dataset 2D	61
5.1.1.2	Treinamento do Autoencoder 2D	62
5.1.1.3	MNIST Dataset 3D	63
5.1.1.4	Treinamento do Autoencoder 3D	64
5.1.2	ES-MDA com Autoencoders para Ajuste de Histórico	64
5.1.2.1	Punq-S3 Benckmark	64
5.1.2.2	Processamento e Assimilação das Sísmica 4D	65
5.1.2.3	Caso Fake 3D	69
5.2	INVERSÃO DE FÁCIES SÍSMICAS	71
5.2.1	Treinamento das Redes Generativas	71
5.2.1.1	Facies Dataset 2D	72
5.2.1.2	Variational Autoencoder 2D	72
5.2.1.3	Generative Adversarial Net 2D	74
5.2.2	ES-MDA com Redes Generativas para Inversão de Fácies Sísmicas	75
5.2.2.1	Fácies Benchmark	75
5.2.2.2	Reparametrização das Fácies e Assimilação da Sísmica 2D	77
5.3	DISCUSSÃO	78
6	CONCLUSÃO	84
7	PUBLICAÇÕES	86
	REFERÊNCIAS	87

1 INTRODUÇÃO

A caracterização e modelagem de reservatórios é um processo importante na indústria de petróleo e gás para gerar modelos de reservatório e fornecer uma melhor compreensão do campo explorado (SANCEVERO *et al.*, 2008). Esta caracterização e modelagem envolve a estimativa de um modelo que contenha as propriedades petrofísicas e elásticas do reservatório, bem como a identificação das diferentes fácies que compõem sua estrutura geológica. Tais fácies são definidas por diferentes tipos de rochas classificadas com base em suas características sedimentares e condições deposicionais (TARANTOLA, 2005). A partir deste modelo é possível melhorar a gestão do campo explorado, podendo ser utilizado para definir canais de fluxo e planejar as melhores posições de perfuração dos poços, visando otimizar o processo de exploração e produção de hidrocarbonetos (CAERS; ZHANG, 2004).

A estimativa das propriedades do reservatório e das fácies é geralmente abordada como um problema inverso, onde se utilizam dados observados, como dados de produção e sísmica 2D, 3D e 4D, para inferir as propriedades internas do reservatório (TARANTOLA, 2005; SEN; STOFFA, 2013; GRANA, 2016). As sísmicas 2D e 3D fornecem uma visão bidimensional e tridimensional da subsuperfície, orientados no plano x,y e na profundidade, enquanto a sísmica 4D, ou de monitoramento sísmico temporal, adiciona-se a dimensão do tempo, permitindo observar as mudanças no reservatório ao longo do tempo devido a produção, como ilustrado na Figura 1. Neste tese, dois exemplos de problemas inversos são abordados, o de ajuste de histórico e o de inversão de fácies sísmicas.

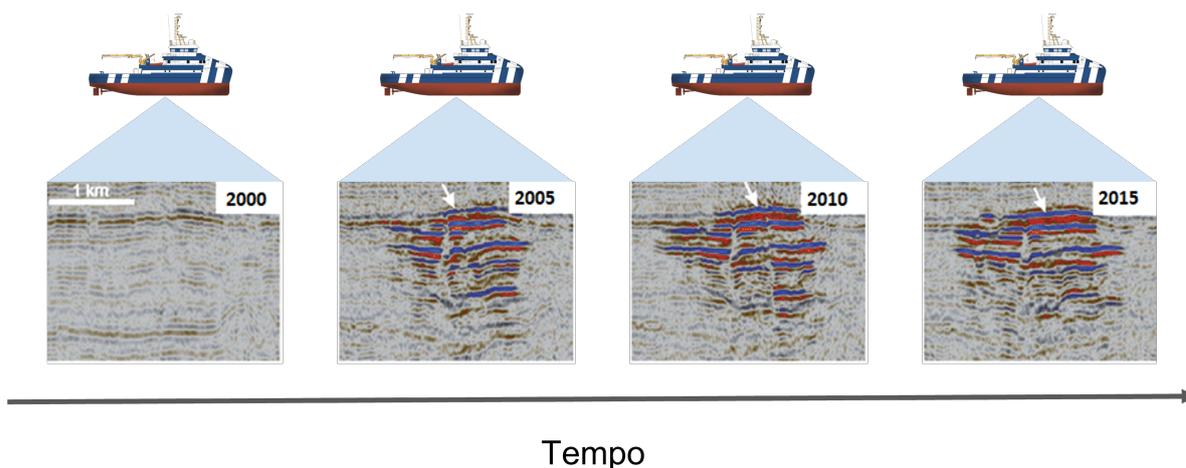


Figura 1 – Processo de aquisição da sísmica 4D.

O ajuste de histórico é um problema inverso onde os parâmetros do modelo de reservatório, tais como porosidade e permeabilidade, são ajustados até que as previsões do modelo correspondam aos dados históricos de produção e sísmica 4D (AANONSEN

et al., 2009; EMERICK, A. A.; REYNOLDS, A. C., 2012; LE; YOUNIS; REYNOLDS *et al.*, 2015). Este processo é vital para melhorar a previsão de comportamento futuro do reservatório. A inversão de fácies sísmicas, por outro lado, visa determinar a distribuição espacial das diferentes fácies dentro do reservatório a partir de dados sísmicos, o que é essencial para a construção de modelos geológicos detalhados (GRANA, 2018).

Para resolver um problema inverso, é necessário um modelo direto ou *forward model*, que a partir dos parâmetros deste modelo, que são as propriedades das rochas ou fácies, simula os dados sísmicos ou dados de produção, que são denominados dados simulados. O problema inversion (ou inversão), então, busca ajustar esses parâmetros do modelo para que o dados simulados com o *forward model* sejam o mais semelhante possível aos dados observados, sendo a informação que realmente é obtida a partir da produção e dos sismógrafos. Outra característica destes problemas inversos é a não-unicidade da solução, onde é possível encontrar diferentes configurações das propriedades de rochas e fácies que são compatíveis com os dados observados. A relação entre parâmetros do modelo e dados observados de um problema inverso para a caracterização de reservatórios é ilustrado na Figura 2.

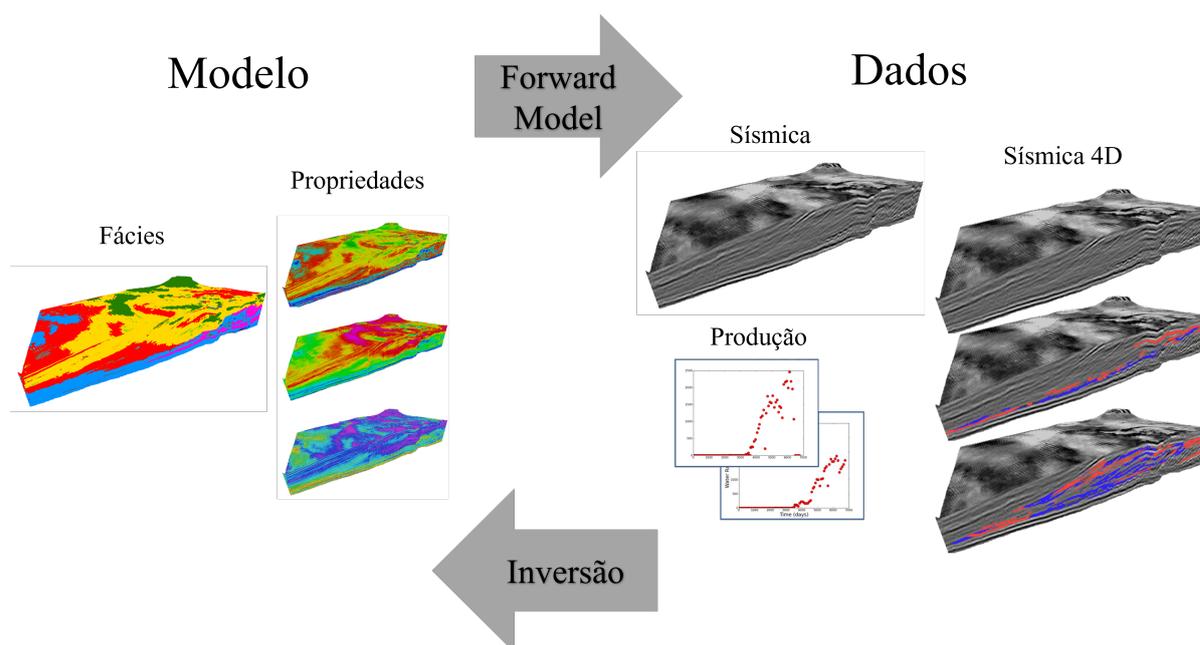


Figura 2 – Ilustração das variáveis do problema inverso, modelo (esquerda) e dados (direita), para a caracterização e modelagem de reservatórios.

A aplicação de dados sísmicos 2D, 3D e 4D para esses problemas não é isenta de desafios. Um dos principais é a banda limitada dos dados sísmicos, que pode resultar em perda de resolução e dificuldade na distinção de detalhes finos das propriedades do reservatório. Grana (2018) também destaca que a relação entre as propriedades do reservatório e os dados sísmicos é frequentemente não linear, tornando a inversão um desafio computacional significativo, sendo muitas vezes necessário técnicas

para linearizar o problema afim de obter um desempenho computacional aceitável, mesmo que isto impacte na acurácia dos resultados (BULAND; OMRE, 2003; GRANA; FJELDSTAD; OMRE, 2017). Além disso, o grande volume de dados sísmicos 4D complica o processamento e a integração com os dados de produção. Portanto, todos estes fatores motivaram o desenvolvimento de métodos de inversão estocásticos, que buscam gerar várias realizações das propriedades de rocha ou fácies, proporcionando uma quantificação da incerteza e um conjunto de soluções com diferentes cenários do modelo do reservatório (FIGUEIREDO; RODRIGUES *et al.*, 2019; GRANA; MUKERJI; DVORKIN *et al.*, 2012; FIGUEIREDO; GRANA; SANTOS *et al.*, 2017).

Atualmente, o Ensemble Smoother with Multiple Data Assimilation (ES-MDA) (EMERICK, A. A.; REYNOLDS, A. C., 2013a) é um método estocástico amplamente aplicado com sucesso para problemas de inversão em geociências. Suas principais vantagens em relação a outros métodos de inversão incluem a eficiência computacional (EMERICK, A. A.; REYNOLDS, A. C., 2013a), a capacidade de lidar com problemas não lineares (EMERICK, A. A.; REYNOLDS, A. C., 2012) e a integração de diferentes tipos de dados (AANONSEN *et al.*, 2009). No entanto, a aplicação do ES-MDA enfrenta desafios quando os dados adquiridos são volumosos, tal como as sísmicas, e quando utiliza informações discretas, como as fácies, para os parâmetros do *forward model*, uma vez que o método pressupõe que esses parâmetros sejam contínuos e possam ser derivados ou representados por distribuições Gaussianas.

No ajuste de histórico com a assimilação das sísmicas 4D utilizando o ES-MDA, o desafio é utilizar eficientemente a grande quantidade de dados da sísmica para atualizar os modelos de reservatório (EMERICK; MORAES; RODRIGUES, 2007; LIU; GRANA, 2020). Já na inversão de fácies sísmicas com ES-MDA, geralmente se utiliza apenas uma sísmica, e o problema está relacionado às informações discretas das fácies que se deseja estimar (CANCHUMUNI, S. W.; EMERICK; PACHECO, M. A. C., 2019; CANCHUMUNI *et al.*, 2021). Portanto, a redução dos dados observados da sísmica 4D, devido ao seu grande volume, e a reparametrização das fácies para um domínio contínuo gaussiano são áreas de pesquisa em aberto para a integração com o ES-MDA e sua aplicação em problemas inversos da área de geociências.

Por outro lado, as redes neurais profundas têm sido amplamente estudadas e utilizadas na indústria de petróleo para processar grandes quantidades de dados e reparametrizar dados discretos com base em distribuições gaussianas (KORJANI *et al.*, 2016; CANCHUMUNI, S. A.; EMERICK; PACHECO, M. A., 2017). Essas redes podem ser treinadas para reconhecer padrões complexos nos dados e por isso são capazes de extrair características ou amostrar o espaço de busca das soluções. O que pode auxiliar a regularizar os processos de inversão na área de modelagem e caracterização de reservatórios (RAEESI *et al.*, 2012; CANCHUMUNI, S. W.; EMERICK; PACHECO, M. A. C., 2019; LIU; GRANA, 2020).

Atualmente, a integração de redes neurais profundas com o ES-MDA tem sido

objeto de estudo do estado da arte e se mostrou uma abordagem promissora para o problema de ajuste de histórico com a assimilação da sísmica 4D (CANCHUMUNI, S. W.; EMERICK; PACHECO, M. A. C., 2019; LIU; GRANA, 2020) e inversão de fácies sísmicas (CANCHUMUNI *et al.*, 2021). A principal vantagem está na redução dos dados de sísmica 4D utilizando redes autoencoders (LIU; GRANA, 2018b) e na reparametrização das fácies do reservatório para um espaço contínuo gaussiano com redes generativas (CANCHUMUNI, S. W.; EMERICK; PACHECO, M. A. C., 2019). No entanto, as principais limitação na integração do ES-MDA com redes neurais profundas são: a necessidade de retreinamento do autoencoder para extração de características das sísmicas; e a não preservação da correlação espacial no espaço reduzido quando utilizada estruturas nas redes neurais com camadas de rede totalmente conectadas.

Este trabalho traz a proposta uma metodologia com melhorias na integração de redes neurais profundas com ES-MDA para dois problemas inversos: um para ajuste de histórico para a assimilação da sísmica 4D e outro para inversão de fácies sísmicas. Em relação ao ajuste de histórico, será utilizada redes neurais profundas do tipo Autoencoder (2D e 3D), inovando ao pré-treinar essas redes com imagens naturais e ajustá-las para a redução dos dados de sísmica 4D com *transfer-learning*. Na inversão de fácies sísmicas, serão utilizadas as redes generativas para a reparametrização das fácies para distribuições gaussianas. Um diferencial das redes neurais propostas é a utilização exclusiva de camadas convolucionais em suas arquiteturas (LONG; SHE-LHAMER; DARRELL, 2015), preservando a correlação espacial no espaço latente e facilitando sua integração com ES-MDA. Para o problema inverso de ajuste histórico com assimilação de sísmica 4D, os resultados indicam que a metodologia proposta reduz significativamente o tempo de execução do ES-MDA ao trabalhar com dados sísmicos reduzidos com Autoencoders. Enquanto para o problema de inversão de fácies sísmicas, os resultados mostraram um ganho de precisão na estimativa das fácies com a utilização de redes generativas totalmente convolucionais para representação das fácies.

1.1 OBJETIVO GERAL

O objetivo principal deste trabalho é oferecer metodologias baseadas em Redes Neurais Profundas em conjunto com Ensemble Smoother with Multiple Data Assimilation para resolução de problemas de inversão no contexto de caracterização de reservatórios.

1.1.1 Pergunta de Pesquisa

Como as redes neurais profundas podem otimizar o processo de inversão na metodologia Ensemble Smoother with Multiple Data Assimilation?

1.1.2 Hipóteses

As redes neurais profundas do tipo Autoencoder são conhecidas por sua capacidade de representar um conjunto de dados em um espaço reduzido sem grandes perdas de informação. Apesar de exigirem um grande volume de dados para treinamento, é possível adaptar um Autoencoder pré-treinado para a redução de dados sísmicos, resultando em um ganho significativo no processo de atualização dos modelos de reservatórios com ES-MDA para ajuste de histórico utilizando sísmicas 4D.

Além disso, redes neurais generativas, capazes de reparametrizar dados para um espaço latente gaussiano, podem fazer com que o ES-MDA trabalhe com qualquer tipo de informação, inclusive dados discretos ou categóricos, possibilitando a aplicação do método para inversão de fácies sísmicas.

1.1.3 Objetivos Específicos

Para atingir o objetivo principal, os seguintes objetivos específicos deverão ser alcançados:

- Realizar uma revisão dos modelos Autoencoder e generativos mais recentes da literatura;
- Desenvolver uma metodologia para extrair características da sísmica 4D para ajuste de histórico e reparametrizar dados de fácies para inversão de fácies sísmicas, permitindo seu uso em métodos baseados em Ensemble Smoother;
- Obter conjuntos de dados para treinamento dos modelos de redes neurais profundas Autoencoder e generativas;
- Abordar de forma inédita os modelos totalmente convolucionais com Ensemble Smoother e utilizar técnicas de transfer-learning para ajustar a rede para diferentes modelos de reservatórios;
- Aplicar a metodologia em benchmarks de ajuste de histórico e comparar os resultados entre as diferentes redes profundas, Autoencoders e generativas, integradas com Ensemble Smoother para ajuste de histórico e inversão de fácies sísmicas;
- Analisar e discutir os resultados, destacando as particularidades de cada rede profunda.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, o objetivo é apresentar o contexto sobre problemas inversos e suas aplicações no processo de caracterização de reservatórios em dois problemas principais: ajuste de histórico e inversão de fácies sísmicas. Além disso, será introduzido o método Ensemble Smoother with Multiple Data Assimilation, que é comumente utilizado para resolver os problemas de inversão na indústria de petróleo, bem como suas vantagens e desafios. Por fim, serão apresentados alguns dos principais modelos de redes neurais profundas e sua integração com ES-MDA para o processamento e extração de características de dados de reservatório.

2.1 PROBLEMAS INVERSOS

As teorias físicas permitem fazer previsões do comportamento de um sistema de acordo com a sua descrição completa, ou seja, é possível prever o resultado das medidas que este sistema pode gerar. Estas medidas são denominadas variáveis observadas e o processo da predição destas medidas é definido como problema direto (*forward problem*). Já o problema de inversão (*inverse problem*) consiste em utilizar as medidas para inferir os valores dos parâmetros que caracterizam o problema (TARANTOLA, 2005), como ilustrado na Figura 3.

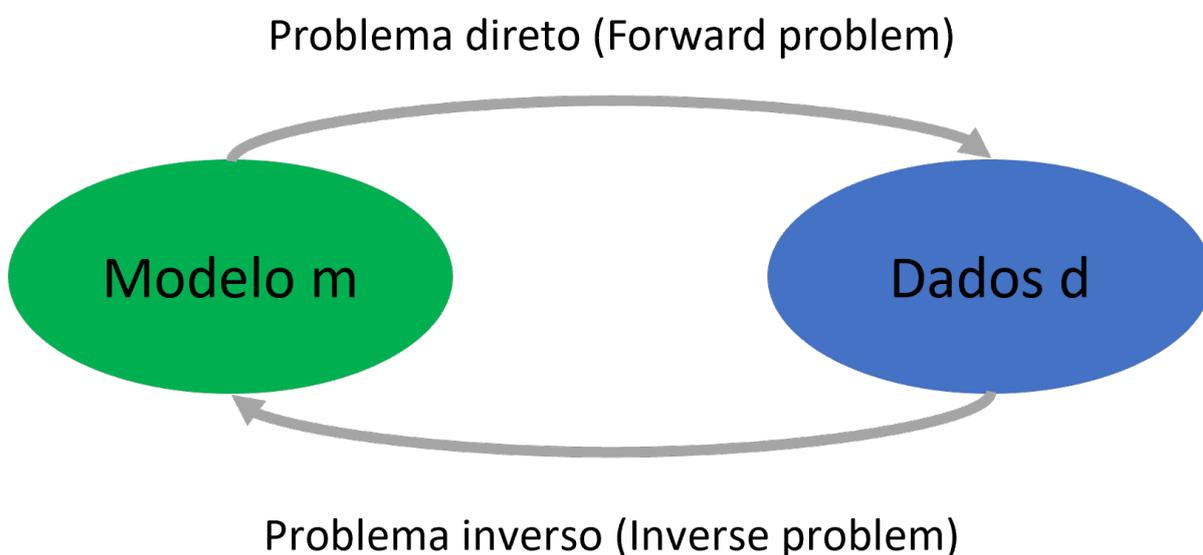


Figura 3 – Ilustração do problema direto e o problema inverso.

Enquanto o problema direto possui uma única solução determinística, o problema inversão é não determinístico e pode possuir diversas soluções possíveis. Por exemplo, dada um simples função matemática como $f(x) = x^2$, se o valor de x é conhecido, $f(x)$ pode facilmente ser calculado. Se $x = 3$, então $f(x) = 9$. Neste caso, temos um

problema direto. Porém, agora considerando o inverso, se $f(x) = 9$, qual será o valor de x ? Neste caso, a resposta não é única, pois tanto $x = 3$ e $x = -3$ satisfazem a equação $f(x) = x^2$.

A formulação geral de um problema inverso é dada considerando as variáveis ou parâmetros de um modelo como m e as medidas coletadas sendo os dados observados como d . Além disso, assume-se que a teoria física que descreve a relação entre ambos é entendida adequadamente através da modelagem direta, *forward model*, definida como G . Normalmente, pode-se assumir algum fator de erro e nestas medidas, já que em casos reais podem haver diversos fatores externos que influenciam na aquisição dessas informações. Desta forma, os dados observados podem ser obtidos a partir da fórmula:

$$d = G(m) + e \quad (1)$$

Apesar da formulação de um problema inverso ser simples, ele é considerado um problema mal posto, como solução não única, como é o caso do $f(x) = x^2$. Portanto, em problemas de inversão mais complexos, existe a necessidade de utilizar métodos estocásticos que ajudam a estimar um conjunto de soluções possíveis para os parâmetros do modelo m .

Na exploração de petróleo e gás, é comum encontrar diversos desafios que são denominados problemas inversos. Dentre as principais estão o desenvolvimento de um modelo de reservatório para a estimativa das propriedades do campo explorado a partir de dados adquiridos da subsuperfície, tais dados sísmico, de poços e de produção.

2.2 CARACTERIZAÇÃO E MODELAGEM DE RESERVATÓRIOS

O processo de caracterização e modelagem de reservatórios é um problema inverso que consiste na determinação tridimensional e quantitativa da estrutura de um reservatório de petróleo, junto com suas propriedades elásticas ou petrofísicas, bem como as fácies do campo explorado (SANCEVERO *et al.*, 2008; FIGUEIREDO; GRANA; SANTOS *et al.*, 2017; GRANA; MUKERJI; DOYEN, 2021). Este processo visa construir um modelo geológico compreensivo que represente a estrutura interna do reservatório e a distribuição de suas propriedades, como porosidade, permeabilidade e saturação de fluidos. A criação de um modelo preciso e realista é vital para prever o comportamento do reservatório sob diferentes condições de produção e para apoiar a tomada de decisões informadas por parte das empresas petrolíferas.

Segundo Ma *et al.* (2005), a caracterização de reservatórios é crucial para prever o potencial econômico de um campo de petróleo e para a análise e geração de diferentes cenários de produção. Esse processo inclui a determinação da arquitetura do reservatório, o estabelecimento das tendências de fluxo dos fluidos e a constru-

ção de modelos que identifiquem o potencial da reserva. Os modelos resultantes são essenciais para prever, monitorar e otimizar os projetos de exploração e produção ao longo do ciclo produtivo do campo. Além de monitorar o campo, esses modelos podem ser usados em estudos de simulação de fluxo, identificando zonas de maior ou menor permeabilidade e gerando mapas de propriedades que ajudam a determinar a estratégia de produção. Com essas informações, é possível caracterizar e gerenciar um reservatório de petróleo de forma eficaz (SANCEVERO *et al.*, 2008).

O desenvolvimento de modelos confiáveis, nos quais o processo de caracterização possa ser realizado de maneira eficiente, pode ser feito de forma determinística ou utilizando uma abordagem probabilística. Historicamente, geólogos e geofísicos criavam seus próprios modelos, que eram posteriormente integrados em um modelo comum do prospecto, campo ou bacia. Atualmente, há esforços para que essa integração ocorra desde o início do processo, com dados sísmicos e de poços sendo interpretados conjuntamente (SANCEVERO *et al.*, 2008; SEN; STOFFA, 2013).

Desde a década de 80, tornou-se comum a utilização de dados sísmicos no processo de modelagem, principalmente para determinar a forma estrutural do campo. Dados sísmicos permitem observar a transição entre diferentes tipos de camadas de rochas, capturadas pela reflexão dessas camadas nos sismógrafos, proporcionando uma imagem estrutural crucial para interpretações geológicas. Além dos modelos geológicos conceituais, dados de perfis, testemunhos e históricos de produção ajudam a aprimorar o modelo do reservatório. Na prática, conforme Sancevero *et al.* (2008), o modelo de reservatório utilizado no processo de caracterização integra diversas informações de diferentes fontes, como dados de poços (porosidade, permeabilidade, fácies, etc.), dados de produção, dados sísmicos, ideias conceituais de especialistas e qualquer outra informação que auxilie no entendimento do campo. A Figura 4 ilustra um modelo de reservatório e suas várias fontes de dados possíveis.

Entretanto, a integração de todas estas informações é uma tarefa matematicamente complexa, devido às diferenças em relação a escala e o fato de a disponibilidade dos dados serem provenientes de diversas fontes. Para que se possa gerar estes modelos integrados, são necessárias técnicas ou metodologias estocásticas que possibilitem a inserção de algum fator de incerteza e condicionamento dos resultados para estas diferentes informações. Neste trabalho, dois problemas inversos são abordados, ajuste de histórico com sísmica 4D e inversão de fácies sísmicas.

2.2.1 Ajuste de Histórico com Sísmica 4D

O ajuste histórico, ou *history matching*, é uma técnica central na modelagem de reservatórios, cujo objetivo é ajustar as propriedades do modelo de reservatório para que suas previsões se alinhem com os dados históricos de produção (EMERICK; MORAES; RODRIGUES, 2007). Essa abordagem geralmente busca estimar propri-

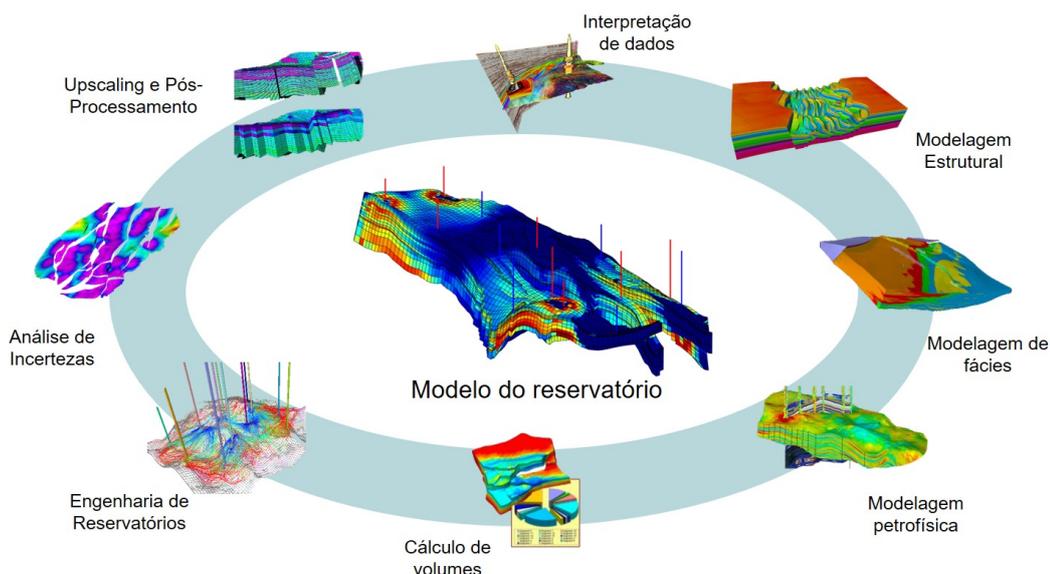


Figura 4 – Ilustração da integração de diversas fontes de dados para a caracterização de modelagem do reservatório.

idades petrofísicas, como porosidade e permeabilidade, que são importantes para descrever o comportamento do fluxo de fluidos no reservatório. A porosidade indica a capacidade do reservatório de armazenar fluidos, e a permeabilidade, determina a facilidade com que os fluidos podem fluir através do reservatório. O processo de ajuste envolve iterativamente modificar estas propriedades no modelo de reservatório até que a resposta do modelo (em termos de produção e pressão) esteja de acordo com os dados observacionais (GOSSELIN *et al.*, 2003).

Tradicionalmente, o ajuste histórico utilizava apenas dados de produção, o que limitava a resolução espacial das propriedades do reservatório que podem não capturar todas as variações espaciais e temporais no reservatório (OLIVER; FOSSUM *et al.*, 2021). Os dados de produção, como taxas de produção de óleo, água e gás, pressões e cortes de água, sendo integrados e obtidos na superfície, fornecem uma visão global do comportamento do reservatório, mas não detalham as variações locais internas. Por outro lado, com a introdução da sísmica 4D, é possível capturar uma imagem mais precisa das mudanças no reservatório ao longo do tempo, proporcionando uma visão mais completa e detalhada (AVANSI; MASCHIO; SCHIOZER, 2016).

Nos últimos anos, a integração de dados sísmicos 4D no processo de ajuste histórico tem sido uma área de pesquisa em foco (OLIVER; FOSSUM *et al.*, 2021; EMERICK, 2019; LIU; GRANA, 2020). A sísmica 4D, ou sísmica de monitoramento temporal, envolve a aquisição de dados sísmicos em diferentes momentos durante o ciclo produtivo do campo. Comparando essas aquisições, é possível observar as mudanças no reservatório causadas pela produção de hidrocarbonetos, como variações na saturação de fluidos e na pressão de poro (LUMLEY; BEHRENS, 1998; HUANG; MEISTER; WORKMAN, 1997; OLIVER; FOSSUM *et al.*, 2021). Por exemplo, à medida

que o óleo é produzido, a substituição de óleo por injeção de água ou gás pode ser detectada através de mudanças nas propriedades do reservatório, observáveis nas sísmicas.

Ao integrar esses dados sísmicos no ajuste histórico, os modelos de reservatório podem ser calibrados de forma mais precisa, resultando em previsões mais confiáveis e eficientes. Além disso, as sísmicas 4D fornecem uma visão detalhada das dinâmicas internas do reservatório, que complementam as informações obtidas a partir dos dados de produção e podem revelar problemas operacionais, como a comunicação entre poços e a eficácia das estratégias de recuperação melhorada (GOSSELIN *et al.*, 2003; LUMLEY; BEHRENS, 1998).

Portanto, o processo de ajuste de histórico com a sísmica 4D envolve a modificação iterativa dos parâmetros do modelo para minimizar a diferença entre os dados simulados e os dados reais de produção (tais como pressões, taxas de produção de óleo, gás e água) e as sísmicas. O objetivo é obter um modelo de reservatório que seja consistente com os dados históricos (produção e sísmica 4D), proporcionando uma base confiável para previsões futuras e tomadas de decisão sobre a gestão do campo, como ilustrado na Figura 5.

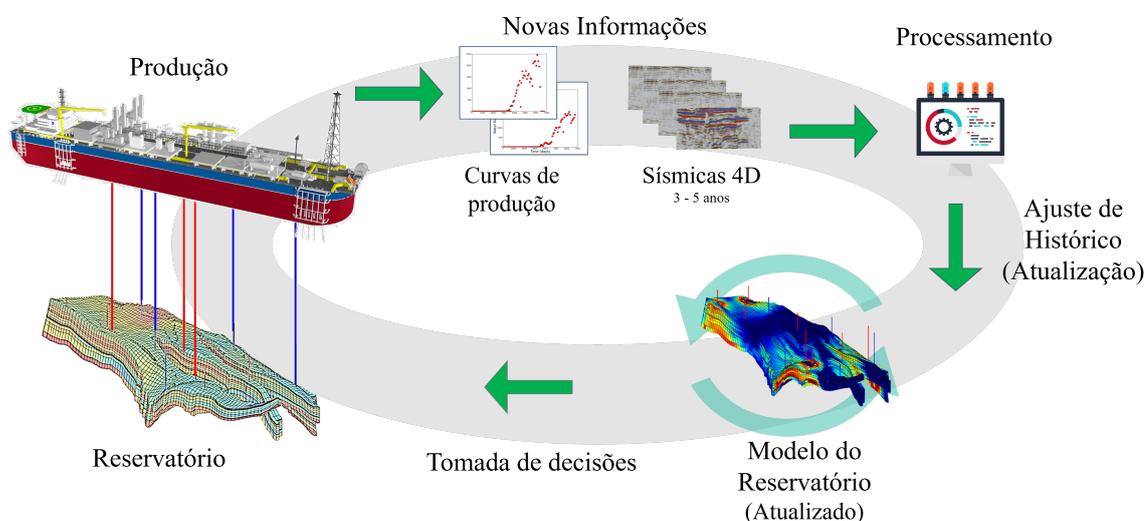


Figura 5 – Ilustração do processo de ajuste de histórico com Sísmica 4D e dados de produção.

Utilizando a equação geral do problema de inversão, no ajuste de histórico utilizando sísmicas 4D, o dado observado $g(m)$ geralmente é a diferença observada entre duas sísmicas adquiridas em instantes de tempo distintos. Os parâmetros do modelo, como porosidade e permeabilidade, são representados por m . A partir do modelo direto g (*forward model*), não é possível obter diretamente a sísmica 4D a partir da porosidade e permeabilidade; portanto, o processo primeiramente utiliza as propriedades petrofísicas (porosidade e permeabilidade) m para obter as propriedades elásticas (impedância e velocidades) e então simular as sísmicas d observadas. A ideia

do processo de inversão do ajuste de histórico é ilustrada na Figura 6.

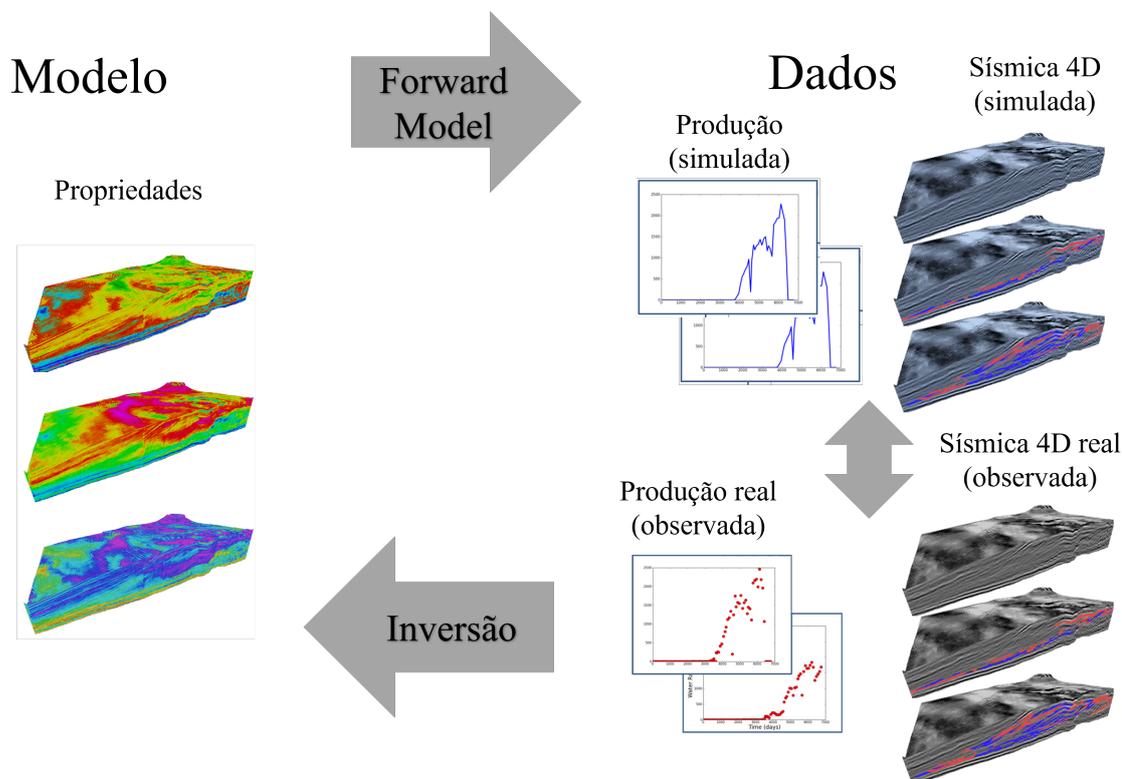


Figura 6 – Processo inverso do ajuste de histórico com as propriedades do reservatório (modelo) e dados (simulados e reais).

No processo da modelagem direta g , esses parâmetros do modelo m são submetidos a um simulador de fluxo que utiliza modelos de porosidade e permeabilidade, juntamente com outros parâmetros do reservatório, para simular o comportamento dos fluidos no reservatório ao longo do tempo. Durante a simulação, esses modelos sofrem alterações que impactam diretamente nas propriedades elásticas e, conseqüentemente, na sísmica. Portanto, a sísmica 4D simulada é o resultado de várias obtenções sísmicas que podem ser obtidas ao longo dessa simulação de produção.

Entretanto, o problema inverso utilizando a sísmica é desafiador, pois múltiplas possibilidades de m podem gerar sísmicas 4D simuladas similares através de $g(m)$, além da grande quantidade de dados a serem processados, o que demanda alto custo computacional. Conseqüentemente, o ajuste de histórico é definido como um problema inverso mal posto, pois pode existir um número infinito de combinações das propriedades m desconhecidas do reservatório que resultam em modelos de reservatório capazes de corresponder às observações d . Como resultado, os modelos de reservatório são construídos com parâmetros incertos. Neste caso, suas previsões ou estimativas também possuem diversas incertezas, o que torna necessário aplicar métodos estocásticos de inversão para estimar as soluções mais prováveis para os parâmetros de um modelo de reservatório que deseja ser estimado.

2.2.2 Inversão de Fácies Sísmicas

A inversão de fácies sísmicas tem como objetivo de estimar a distribuição espacial das fácies, que são as diferentes unidades rochosas com características distintas, a partir de dados sísmicos (SAUSSUS; SAMS, 2012; KEMPER; GUNNING, 2014; GRANA; FIGUEIREDO; PESCO *et al.*, 2020). Segundo Grana (2018), as propriedades contínuas de um reservatório, tal como propriedades de rocha como porosidade e permeabilidade e propriedades elásticas como a impedância são diretamente dependente de informações discretas, neste caso as fácies. As fácies podem ser definidas como um conjunto de rochas com características distintas, com aspecto mineralógico, estrutural ou composicional. Elas são fundamentais para entender as propriedades petrofísicas do reservatório, como porosidade, permeabilidade e saturação de fluidos, pois essas propriedades variam significativamente entre diferentes fácies.

O processo de inversão de fácies sísmicas envolve a utilização de dados sísmicos, que são obtidos através da emissão e recepção de ondas sísmicas na subsuperfície. Esses dados são então analisados para inferir as propriedades elásticas das rochas, como impedância acústica e velocidade das ondas sísmicas. A partir dessas propriedades elásticas, pode-se inferir a distribuição das fácies no reservatório. Além disso, o problema da inversão de fácies sísmicas é caracterizado por uma mistura de propriedades contínuas e discretas (GRANA, 2018; GRANA; FIGUEIREDO; PESCO *et al.*, 2020). As propriedades elásticas obtidas a partir dos dados sísmicos, como impedância e velocidade, são contínuas. Por outro lado, as fácies são categorias discretas que representam diferentes tipos de rochas. Esta combinação de propriedades contínuas e discretas complica ainda mais o processo de inversão, pois os métodos tradicionais de inversão geralmente são projetados para lidar com apenas um tipo de dado (GRANA, 2018).

Da mesma maneira, utilizando a formulação do problema inverso presente na Equação 1, as fácies são representadas por m , o dado observado é a sísmica pós-processada e a modelagem direta, *forward model*, ilustrada na Figura 7 que estima a sísmica simulada a partir das fácies é dada por $g(m)$. No entanto, como mencionando por Grana (2018), não é possível obter a sísmica diretamente das fácies, pois geralmente estima-se em conjunto as fácies e propriedades petrofísicas, para a obtenção das propriedades elásticas e então a sísmica.

Normalmente, o desafio da inversão sísmica, seja para fácies ou outro tipo de propriedade, é a banda limitada do dados sísmicos (GRANA, 2018; FIGUEIREDO; GRANA; BORDIGNON *et al.*, 2018). Naturalmente, como característica do problema de inversão, diversas configurações de modelos de fácies podem satisfazer o dado sísmico observado. Portanto, a inversão de fácies sísmicas também é um problema mal posto, pois diferentes modelos de fácies podem gerar sísmicas muito parecidas a partir da modelagem direta, *forward model*, e por isso são necessários métodos estocásticos

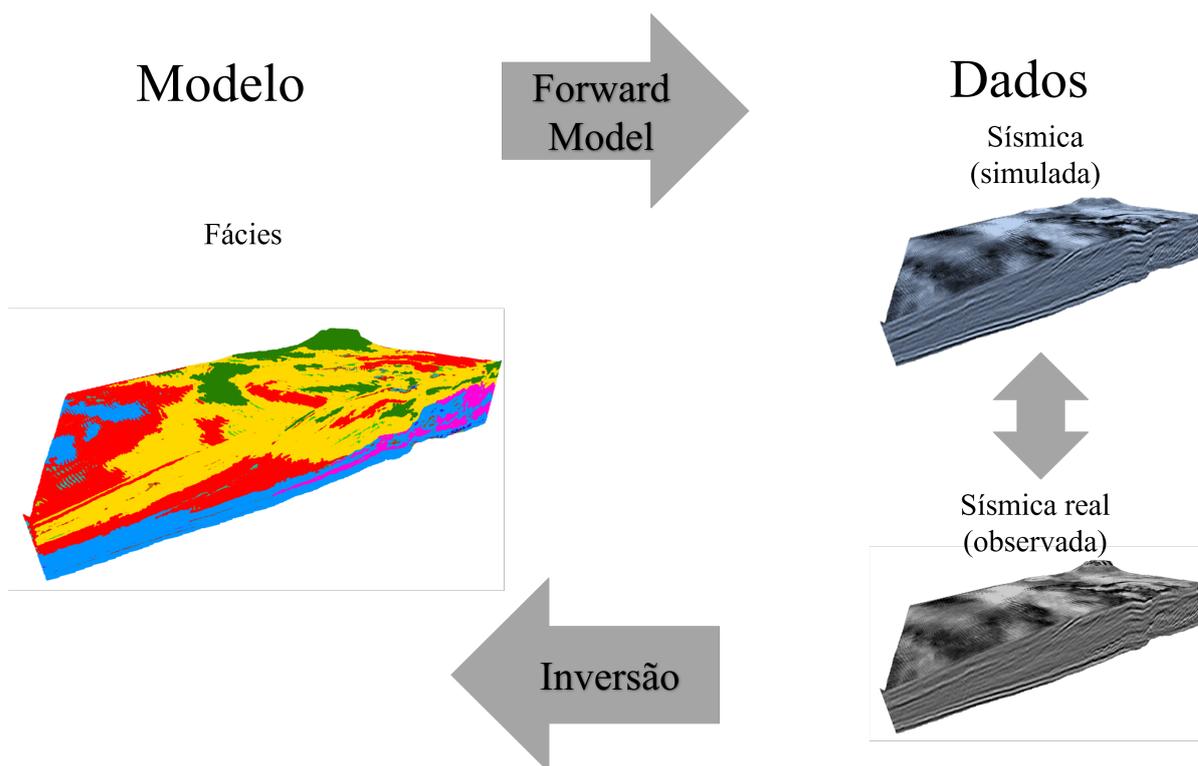


Figura 7 – Ilustração do processo de inversão de fácies sísmicas.

que possibilitem a inserção de algum fator de incerteza e estimem um conjunto de modelos de fácies que satisfaçam a solução (GRANA; FIGUEIREDO; PESCO *et al.*, 2020; FIGUEIREDO; GRANA; BORDIGNON *et al.*, 2018).

2.3 ENSEMBLE SMOOTHER WITH MULTIPLE DATA ASSIMILATION

O Ensemble Smoother with Multiple Data Assimilation (ES-MDA) (EMERICK, A. A.; REYNOLDS, A. C., 2013a) é um método baseado em técnicas de assimilação de dados e têm sido aplicado com sucesso em problemas inversos na área de geociências (AANONSEN *et al.*, 2009; EVENSEN; VOSSEPOEL; LEEUWEN, 2022). Dentre os diversos métodos de inversão, o ES-MDA se destaca devido a sua eficiência computacional (EMERICK, A. A.; REYNOLDS, A. C., 2013a), capacidade de lidar com problemas não lineares (EMERICK, A. A.; REYNOLDS, A. C., 2012), atualização simultânea de múltiplos parâmetros (AANONSEN *et al.*, 2009), a incorporação de diferentes tipos de dados (AANONSEN *et al.*, 2009; LIU; GRANA, 2020, 2018a), redução de erros de amostragem (EMERICK, A.; REYNOLDS, A., 2011) e facilidade de implementação (EVENSEN *et al.*, 2009). Sendo assim, devido à principalmente incorporação de diferentes dados e lidar com problemas não lineares, já que esse método pode ser aplicado então para diferentes problemas inversos e seria um critério eliminatório em relação à outros métodos de inversão devido a necessidade de linearização dos problemas diretos, neste trabalho foi utilizado o ES-MDA.

O ES-MDA tipicamente envolve dois passos principais em um processo iterativo,

onde os dados observados são assimilados novamente e em cada etapa da iteração os parâmetros do modelo são atualizados de acordo com essa informação. Neste processo, o ES-MDA primeiro utiliza o problema direto para prever os dados simulados a partir dos parâmetros iniciais do modelo, e segundo, faz a atualização, ou ajuste, destas variáveis do modelo com base na diferença dos dados observados e os simulados.

O processo ES-MDA começa com um conjunto inicial de realizações prévias, *à priori*, cada uma representando um cenário diferente para as variáveis do modelo m . O tamanho desse conjunto é denotado por N_e , que representa o número de membros da realização. Muitos métodos geoestatísticos podem ser usados para gerar esse conjunto (GRANA; MUKERJI; DOYEN, 2021) com base nas informações prévias. No próximo passo, esse conjunto é usado como um parâmetro para o *forward model* g , resultando em um conjunto de dados sísmicos simulados $g(m^k)$, com $k = 0$ sendo a iteração inicial. Este processo iterativo continua até que o número predeterminado de iterações de assimilação de dados N_a seja satisfeito.

A equação de atualização do modelo ES-MDA é definida como:

$$m_j^{k+1} = m_j^k + \tilde{K}(d_{obs,j}^k - g(m_j^k)) \quad (2)$$

para $j = 1, \dots, N_e$ representando cada realização no conjunto, onde m denota o vetor das variáveis do modelo, k indica a iteração da atualização, $d_{obs,j}^k$ refere-se à perturbação estocástica dos dados observados, e \tilde{K} é a matriz de ganho de Kalman (EVENSEN *et al.*, 2009). Esta matriz \tilde{K} é computada a partir das matrizes de covariância de m e d , denotadas como:

$$\tilde{K} = C_{md}^k (C_{dd}^k + \alpha_k C_e)^{-1}, \quad (3)$$

onde C_{md} é a matriz de covariância cruzada entre m e d , C_{dd} é a matriz de auto-covariância de d , α_k representa os coeficientes do fator de inflação, e C_e é a matriz de covariância associada ao erro de medição dos dados observados. Ambas as matrizes de covariância C_{md} e C_{dd} são computadas com base no modelo e na previsão, m^k e $g(m^k)$, da última iteração.

A diferença entre cada dado simulado do ensemble com o dado observado pode ser computada através de uma função objetiva, onde o objetivo é minimizar esse erro, que é dada pela equação:

$$O_d(m_j) = \frac{(d_{obs} - g(m_j))^T C_d (d_{obs} - g(m_j))}{N_d} \quad (4)$$

onde N_d é a quantidade de dados. Mais informações sobre a função objetiva pode ser encontrada em (OLIVER; REYNOLDS; LIU, 2008).

Dentre os desafios do ES-MDA destacam-se que para as variáveis do modelo m assume-se que elas possam ser representadas ou obtidas a partir de distribuições

Gaussianas. Além disso, a dimensionalidade de d em problemas complexos pode conter uma grande quantidade de dados e de alta dimensionalidade, onde muitas vezes pode existir redundância dessas informações, ou seja, os dados observados são muito parecidos e sua grande maioria e, no caso do ES-MDA, pode afetar a performance do método. De acordo com (EMERICK, A.; REYNOLDS, A., 2011), uma das estratégias para reduzir as informações redundantes e evitar correlações espúrias é a utilização de métodos para localização de covariância. Em relações a grande quantidade de dados observados, atualmente se explora a utilização de redes neurais profundas para a redução dimensional dessas informações (LIU; GRANA, 2020) e para a reparametrização das variáveis do modelo para distribuições Gaussianas (CANCHUMUNI, S. A.; EMERICK; PACHECO, M. A., 2017; CANCHUMUNI *et al.*, 2021).

2.3.1 Localização de Covariância

O método de localização de covariância (EMERICK, A.; REYNOLDS, A., 2011) é um procedimento normalmente utilizado no Ensemble Smoother para reduzir correlações espúrias causadas por erros de amostragem durante o processo de assimilação. A maioria das técnicas de localização de covariância são baseadas por distância, ou seja, assume-se que dado um ponto de um reservatório, somente as informações posicionados dentro de uma certa distância espacial daquele ponto devem afetar a análise naquela informação. A ideia é multiplicar a matriz de covariância por uma matriz de localização \mathbf{R} , que é geralmente uma função decrescente da distância entre os pontos.

A matriz de localização \mathbf{R} pode ser definida como uma matriz de correlação, onde \mathbf{R}_{ij} é a correlação entre os pontos i e j . Um exemplo comum é o uso de uma função gaussiana para definir a matriz de localização:

$$\mathbf{R}_{ij} = \exp\left(-\frac{d_{ij}^2}{2l^2}\right)$$

onde d_{ij} é a distância entre os pontos i e j , e l é um parâmetro de escala que define o alcance da localização. De acordo com (EMERICK, A.; REYNOLDS, A., 2011), a escolha do parâmetros desse alcance da localização é um desafio.

A matriz de localização \mathbf{R} pode ser aplicada diretamente na matriz de ganho de Kalman através do produto Schur, onde cada posição de uma matriz é multiplicada com a mesma posições de outra matriz. Por exemplo, a matriz de ganho do Kalman pode ser multiplicada por uma matriz de localização que contém pesos baseados na distância entre as localizações das observações e os pontos do modelo. Portanto, um dos parâmetros mais importantes necessária para a localização de covariância baseada em distância é a escolha do comprimento de correlação para construir a matriz de correlação. A equação do ES-MDA com o método de localização é definida como:

$$m_j^{k+1} = m_j^k + R \circ \tilde{K}(d_{obs,j}^k - g(m_j^k)) \quad (5)$$

com R sendo a matriz de localização da covariância, com dimensão igual à \tilde{K} , sendo multiplicada diretamente com R via produto Schur, onde cada elemento da posição da matriz é multiplicada com o elemento da mesma posição da outra.

Essas técnicas de localização são essenciais para garantir que o ES-MDA produza resultados realistas e consistentes, especialmente em modelos de reservatório de grande escala, onde normalmente se tem grande quantidade de dados para serem assimilados e as correlações espúrias podem ter um impacto significativo nos resultados (EMERICK, A. A.; REYNOLDS, A. C., 2013a,b).

2.3.2 Aplicação e Desafios em Problemas Inversos

Sendo o ES-MDA um dos métodos que vem sendo aplicado com sucesso para ajuste de histórico, o principal desafio é que o processamento sísmica 4D durante o processo iterativo do método, que demanda alto custo computacional, pois para volumes sísmicos 3D normalmente existem grande quantidade de dados e redundância destas informações. A implementação do ES-MDA para assimilar grandes quantidades de pontos de dados requer atenção especial nas operações matriciais, especialmente em termos dos requisitos de memória, porque as dimensões das matrizes C_{md} e C_{dd} crescem drasticamente. Por exemplo, uma implementação simples da equação de atualização em um caso com 10^6 parâmetros e 10^6 pontos de dados exigiria 8 TB para armazenar a matriz C_{md} . Portanto, trabalho mais recentes propuseram a utilização de redes neurais profundas do tipo autoencoder para a extração da características dos dados observados, tal como a sísmica 4D, e utilizar a informação extraída reduzida no processo do ES-MDA.

O ES-MDA também pode ser aplicado para inversão de fácies sísmicas, para estimar um conjunto de possíveis soluções para m que satisfazem d . Porém, um dos desafios é a utilização de dados discretos, como as fácies, para o processo de atualização do ES-MDA, definido na Equação 3. Além disso, no caso da inversão de fácies sísmicas, o ES-MDA assume que m , as fácies, possam ser derivadas ou representadas a partir de amostras gaussianas (EMERICK, A. A.; REYNOLDS, A. C., 2013a; CANCHUMUNI, S. A.; EMERICK; PACHECO, M. A., 2017). Neste caso, a utilização de redes neurais com arquiteturas profundas do tipo generativas se tornaram foco para a reparametrização das variáveis do modelo m para amostras Gaussianas, devido a possibilidade destas redes conseguirem gerar amostras de fácies a partir de uma espaço latente reduzido contínuo e gaussiano (CANCHUMUNI, S. A.; EMERICK; PACHECO, M. A., 2017; LIU; GRANA, 2018b). Dentre os destaques, estão as redes neurais profundas (RNP) do tipo Variational autoencoder (VAE) e as Generative Adversarial Nets (GAN).

2.4 REDES NEURAIS PROFUNDAS

Uma Rede Neural Artificial (RNA) é um sistema massivamente paralelo e distribuído, composto por unidades de processamento simples que possuem uma capacidade natural de armazenar conhecimento e torná-lo disponível para uso (HAYKIN, 1994). Dentre os diversos modelos propostos, as RNAs podem ser categorizadas de duas maneiras: redes de aprendizagem supervisionada (RUMELHART; HINTON; WILLIAMS, 1986) e redes de aprendizagem não supervisionada (KOHONEN *et al.*, 2001). As redes supervisionadas são treinadas com um conjunto de dados de saída conhecido, enquanto as redes de aprendizagem não supervisionada são treinadas apenas com os dados disponíveis, sem uma saída conhecida.

Ao longo dos anos, desde o surgimento das RNAs, diversos modelos foram desenvolvidos para resolver diferentes classes de problemas, tal como classificação, segmentação e extração de características. Atualmente, as redes neurais são amplamente utilizadas em diversas áreas devido à sua alta capacidade de processamento, combinada com a evolução dos hardwares, principalmente as GPUs (graphics processing unit), e sua capacidade de inferência a partir de conjuntos de dados.

Redes Neurais Profundas (RNP), ou deep neural networks (DNNs), são um subconjunto de redes neurais artificiais que possuem múltiplas camadas entre a entrada e a saída. Essas redes são projetadas para modelar padrões complexos em grandes volumes de dados, usando algoritmos de aprendizado de máquina inspirados na estrutura e funcionamento do cérebro humano. A estrutura de uma rede neural profunda é geralmente composta por diversas camadas de neurônios organizadas sequencialmente, onde cada camada é responsável por uma série de operações que transformam os dados de entrada em representações abstratas, com ilustrado na Figura 8.

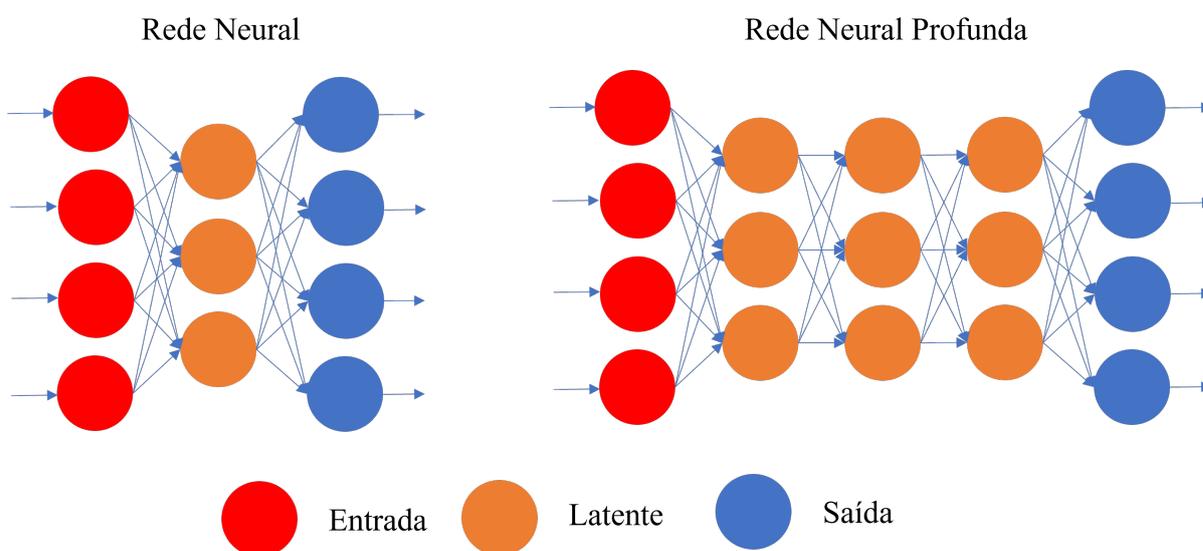


Figura 8 – Comparativo entre rede neural tradicional (esquerda) e rede neural profunda (direita).

A primeira camada de entrada recebe os dados brutos diretamente. Posteriormente,

te, os dados processados pela camada de entrada passam para as camadas ocultas, que são responsáveis por extrair e aprender representações hierárquicas dos dados. Para isso, são utilizadas funções de ativação que introduzem a não linearidade nos dados de entrada, permitindo que a rede neural aprenda representações mais complexas. Por exemplo, a função de ativação Rectified Linear Unit (ReLU) é comumente utilizada devido à sua simplicidade e eficiência, ajudando a evitar que o gradiente fique com valores muito pequenos, próximos de zero, prejudicando o processo de aprendizado da rede.

2.4.1 Redes Neurais Convolucionais

Em 1989, [LeCun et al. \(1989\)](#) introduziu o conceito de Redes Neurais Convolucionais (RNC). As RNCs são um tipo especial de Rede Neural projetadas para lidar com dados em formato de grade ou com topologia específica. Exemplos comuns incluem séries temporais (grades 1D com amostras em intervalos de tempo) e dados de imagem (grades 2D de pixels) ([KRIZHEVSKY; SUTSKEVER; HINTON, 2012](#)). O termo "convolucional" deriva do uso de camadas que realizam a operação matemática chamada convolução. [Goodfellow, Bengio e Courville \(2016\)](#) definem uma Rede Neural Convolucional como uma rede neural que emprega a convolução em vez de operações de multiplicação de matrizes, em pelo menos uma de suas camadas.

Atualmente, as Redes Neurais Convolucionais são amplamente estudadas em diversas aplicações, incluindo classificação, extração de características e reconstrução de imagens ([KRIZHEVSKY; SUTSKEVER; HINTON, 2012](#); [KALCHBRENNER; GREFFENSTETTE; BLUNSOM, 2014](#); [KIM, 2014](#); [ZHANG; WU; ZHU, 2018](#)). Em particular, as redes totalmente convolucionais ([LONG; SHELHAMER; DARRELL, 2015](#)) têm demonstrado excelente desempenho em várias aplicações de visão computacional, evidenciando a eficácia das arquiteturas profundas e convolucionais na modelagem e interpretação de dados visuais complexos.

A arquitetura de uma RNC é composta por várias camadas que processam os dados de entrada de maneira hierárquica. As principais camadas de uma RNC incluem:

- Camada Convolutiva: Utiliza filtros, ou kernels, que deslizam sobre a entrada para capturar características locais, como bordas e texturas. Cada filtro produz um mapa de características que representa a presença de padrões específicos na entrada.
- Camada de Agrupamento (Pooling): Reduz a dimensionalidade dos mapas de características, resumindo a presença de características em regiões menores. Isso ajuda a tornar a rede mais robusta a variações e distorções nas entradas.
- Camada Totalmente Conectada (Fully Connected): Após várias camadas convolutivas e de agrupamento, a rede utiliza uma ou mais camadas totalmente

conectadas para classificar os dados com base nas características extraídas.

Supondo um problema onde é necessário treinar uma Rede Convolutiva para classificar rostos humanos entre duas classes: feliz e triste. Para simplificar, supondo que as imagens sejam somente em preto e branco. Dada uma matriz de tamanho 3×3 , denominada filtro convolutivo ou *kernel*. A Figura 9 ilustra uma imagem de rosto com a expressão feliz, com a matriz representando as cores dos pixels variando entre 0 e 1, enquanto a Figura 10 mostra a matriz ilustrando o *kernel*.

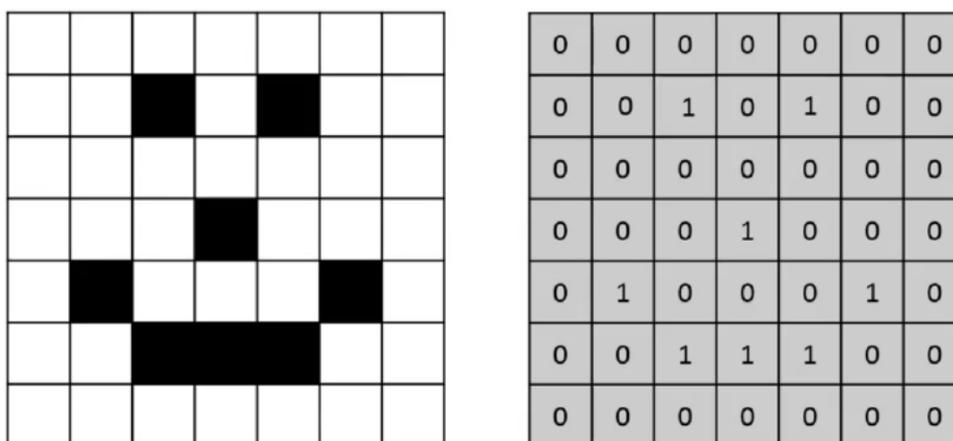


Figura 9 – Representação de um rosto sorrindo (esquerda) e a representação em uma matriz de valores entre 0, para branco e 1, para preto (direita). Adaptado de [Goodfellow, Bengio e Courville \(2016\)](#).

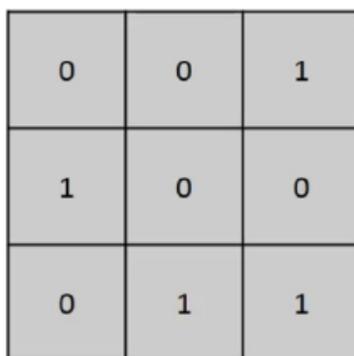
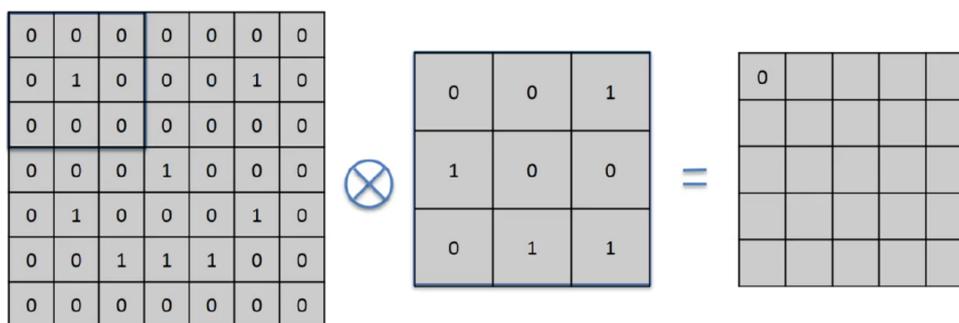


Figura 10 – Exemplo de representação da matriz de parâmetros 3×3 chamada de *kernel*. Adaptado de [Goodfellow, Bengio e Courville \(2016\)](#).

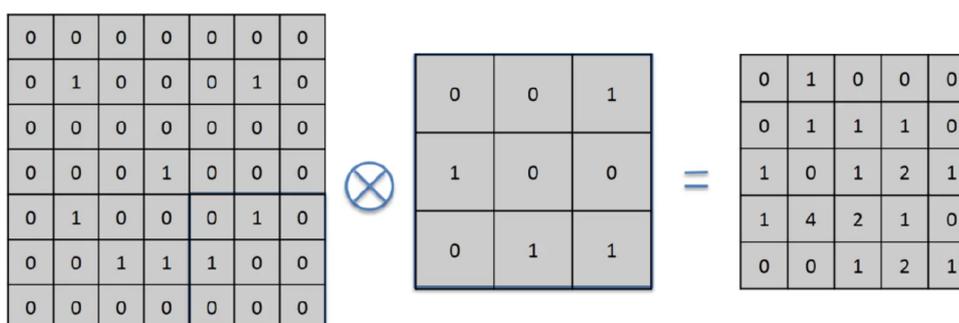
Primeiramente, o *kernel* é sobreposto ao canto superior esquerdo da matriz de valores que representa a imagem de entrada. Em seguida, é realizado o produto elemento a elemento do *kernel* sobreposto com os valores da imagem de entrada, gerando uma matriz 3×3 . Todos os coeficientes desta matriz são somados, gerando o coeficiente (1,1) da matriz de características, ou mais comumente, mapa de características.

O *kernel* é então movido para a direita, em um passo denominado *stride*. O tamanho do *stride* pode ser definido como um pixel para a direita. Após mover o *kernel*, a mesma operação é realizada para a obtenção do coeficiente (1,2) do mapa de

características e assim sucessivamente. A Figura 11 ilustra intuitivamente a operação de convolução realizada no treinamento da Rede Neural Convolutacional.



(a) Início da convolução



(b) Final da convolução

Figura 11 – Ilustração do início da operação convolução (a) e o mapa de característica obtido ao final após mover o *kernel* por toda a imagem (b). Da esquerda para a direita: pesos da imagem de entrada, *kernel* e o mapa de características. Adaptado de Goodfellow, Bengio e Courville (2016)

No contexto da Rede Neural Convolutacional, a aplicação de diversos *kernels* sobre a imagem de entrada gera diversos mapas de características. Esses mapas de características são empilhados, formando a Camada Convolutacional (CONV). Para cada um destes mapas de características, podem ser aplicados novamente diferentes *kernels* para obter novos mapas de características, formando a camada convolutacional seguinte. A Figura 12 ilustra a estrutura de uma Rede Neural Convolutacional.

Cada *kernel* possui uma dimensão reduzida em relação aos dados de entrada, porém ele possui a mesma profundidade da imagem. Por exemplo, se uma imagem de entrada possui dimensão 100×100 e ela for colorida em tons RGB, então sua profundidade é 3. Portanto, o *kernel* pode ser definido como $3 \times 3 \times 3$, onde a última dimensão corresponde à profundidade da imagem de entrada. A Figura 13 mostra um exemplo da aplicação de *kernels* com a mesma profundidade dos dados de entrada.

O tamanho do mapa de características é controlado pelo tamanho do passo *stride*. Quanto maior o *stride*, menor será o tamanho do mapa de características. A redução da imagem de entrada para os mapas de características é fundamental para que a Rede Neural Convolutacional aprenda somente as características mais importantes, agilizando o processo de treinamento. A função do *kernel* é justamente detectar estas

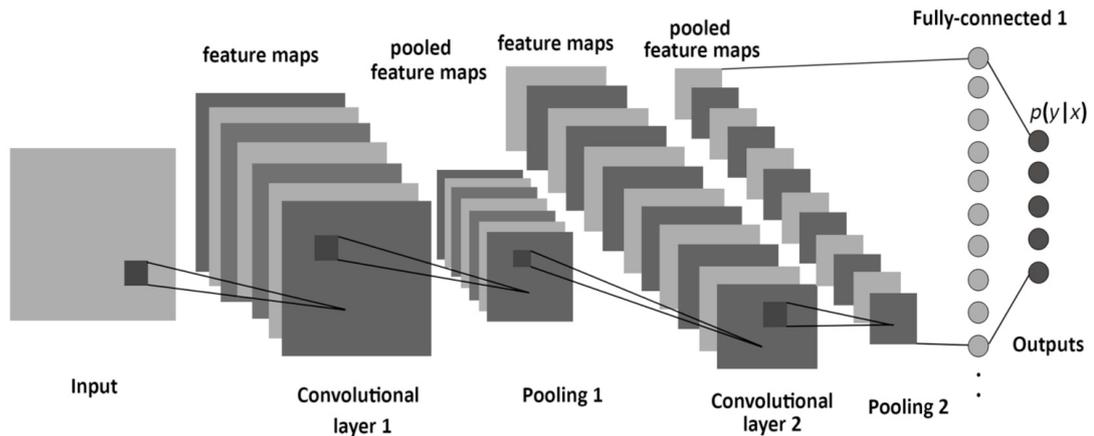


Figura 12 – Exemplo de uma estrutura de uma Rede Neural Convencional. Adaptada de [Albelwi e Mahmood \(2017\)](#).

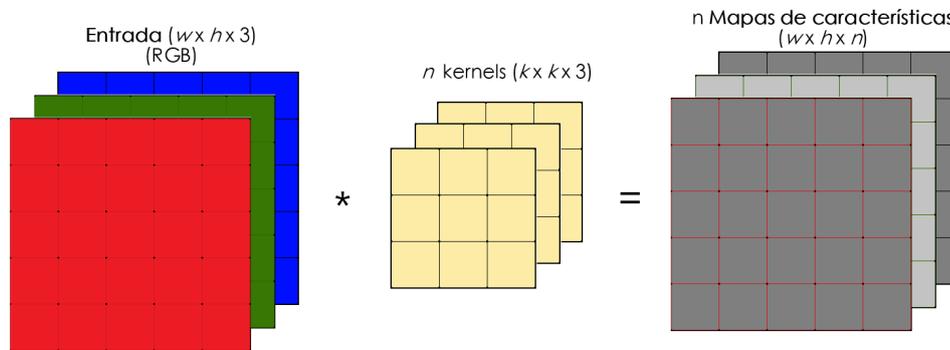


Figura 13 – Aplicação de n kernels de tamanho $k \times k \times 3$ em uma entrada de tamanho $w \times h \times 3$. O resultado são n mapas de características de tamanho $w \times h$.

características nas imagens de entrada.

Segundo [Goodfellow, Bengio e Courville \(2016\)](#), diferentes kernels possibilitam a identificação de diferentes características. Portanto, diversos kernels são utilizados durante o treinamento da Rede Neural Convencional, podendo até ser definidos com tamanhos diferentes. A Figura 14 mostra a aplicação de diferentes kernels para uma mesma imagem.

Em termos formais, a entrada de cada camada convolucional (CONV) l é o conjunto de $n^{(l-1)}$ mapas de características extraídas pela camada anterior, com dimensão $w^{(l-1)} \times h^{(l-1)}$. Caso l seja a primeira camada da rede, sua entrada pode ser uma imagem I composta de n canais. A saída da camada convolucional consiste em $n^{(l)}$ mapas de características com dimensões $w^{(l)} \times h^{(l)}$. O mapa de número i , na camada l (neste caso $M_i^{(l)}$), é representado da seguinte forma:

$$M_i^{(l)} = B_i^{(l)} + \sum_{j=1}^{n^{(l-1)}} K_{i,j}^{(l)} * M_j^{(l-1)} \quad (6)$$

onde $B_i^{(l)}$ é uma matriz contendo o bias e $K_{i,j}^{(l)}$ é o filtro a ser aplicado nos dados de entrada.

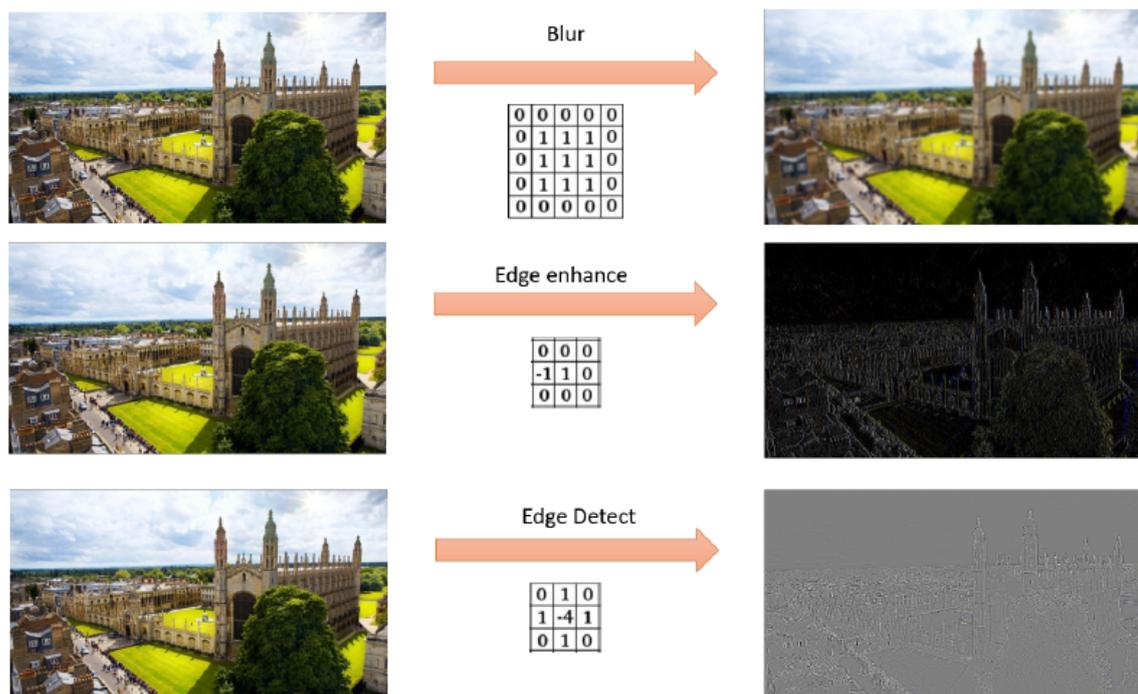


Figura 14 – Exemplo dos mapas de características obtidos a partir de diferentes *kernels* (GOODFELLOW; BENGIO; COURVILLE, 2016).

Logo após a convolução, é comum aplicar uma função de ativação. A função de ativação presente em cada neurônio é responsável por aplicar uma transformação nos dados recebidos. A camada *pooling* é geralmente utilizada após uma camada convolucional para a redução da dimensionalidade dos atributos, aumentando a performance da rede. No caso de uma camada *pooling* de dimensões (2, 2) aplicada sobre um mapa de características de (4, 4), o resultado é um mapa de características de dimensões (2, 2).

O cálculo da saída de uma camada *pooling* pode ser definido de diversos modos, aplicando alguma função em todos os elementos de uma determinada região. Geralmente, os trabalhos encontrados na literatura fazem uso de *Average Pooling* ou *Max Pooling*. No primeiro, é feito o cálculo da média dos elementos para se obter a saída; no segundo, o valor da saída é o maior elemento de determinada região. É importante mencionar que a camada *pooling* não reduz a profundidade da entrada, somente a largura e altura do campo perceptivo dos filtros da RNC. A Figura 15 mostra um exemplo da operação *pooling*, onde a entrada é dividida em janelas 4x4, e para cada uma destas janelas é utilizada a função *Max Pooling*.

Além de reduzir a dimensão dos filtros e dos parâmetros da rede, a camada *pooling* também é essencial para criar invariância espacial (GOODFELLOW; BENGIO; COURVILLE, 2016). A invariância espacial permite identificar o mesmo padrão em qualquer local dos dados de entrada. Por exemplo, para entradas do tipo imagem, onde o objetivo é identificar as rodas de um carro, independente da sua localização na imagem, elas serão identificadas da mesma forma pelos mapas de características.

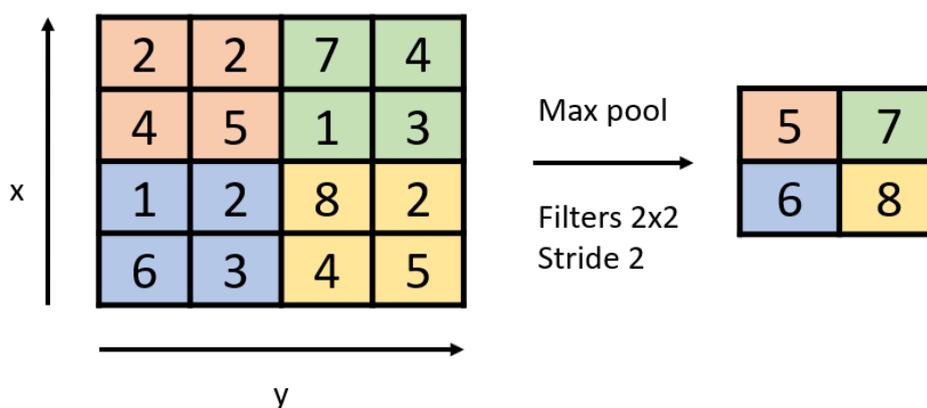


Figura 15 – Operação de Pooling utilizando a função de máximo. Adaptada de Exterkoetter *et al.* (2018).

2.4.2 Autoencoders

De acordo com Goodfellow, Bengio e Courville (2016), um Autoencoder (AE) é um tipo de Rede Neural não supervisionada, na qual o mesmo conjunto de dados é usado tanto como entrada quanto como saída. O objetivo principal de um AE é aprender uma representação compacta e eficiente dos dados, chamada de codificação.

O AE recebe uma entrada $\mathbf{x} \in \mathbb{R}^d$ e a mapeia para uma representação latente $\mathbf{z} \in \mathbb{R}^m$ (onde m é geralmente menor que d), utilizando uma função determinística da forma:

$$\mathbf{z} = f_{\theta}(\mathbf{x}) = \sigma(W\mathbf{x} + b)$$

Aqui, $\theta = \{W, b\}$ representa os parâmetros da rede, com W sendo os pesos e b o bias. A função σ é uma função de ativação não linear, como a ReLU ou a sigmoide, que introduz não linearidade no modelo.

Essa representação latente \mathbf{z} , ou "codificação", é então usada para reconstruir a entrada original através de um mapeamento reverso:

$$\hat{\mathbf{x}} = f_{\theta'}(\mathbf{z}) = \sigma(W'\mathbf{z} + b')$$

Neste caso, $\theta' = \{W', b'\}$ são os parâmetros do decodificador. Muitas vezes, os pesos do decodificador são restritos para serem a transposta dos pesos do codificador, ou seja, $W' = W^T$. Isso significa que os mesmos pesos são usados tanto para a codificação quanto para a decodificação.

Durante o treinamento, cada exemplo de treinamento x_i é mapeado para sua codificação z_i e, em seguida, para sua decodificação (ou reconstrução) \hat{x}_i . O objetivo é otimizar os parâmetros da rede minimizando o erro de reconstrução, que é medido por uma função de custo, como o erro quadrático médio (MSE), sobre o conjunto de treinamento $D_n = \{x_0, x_1, \dots, x_n\}$. A Figura 16 ilustra o modelo de um Autoencoder, mostrando como a entrada é comprimida na codificação e depois reconstruída na

saída.

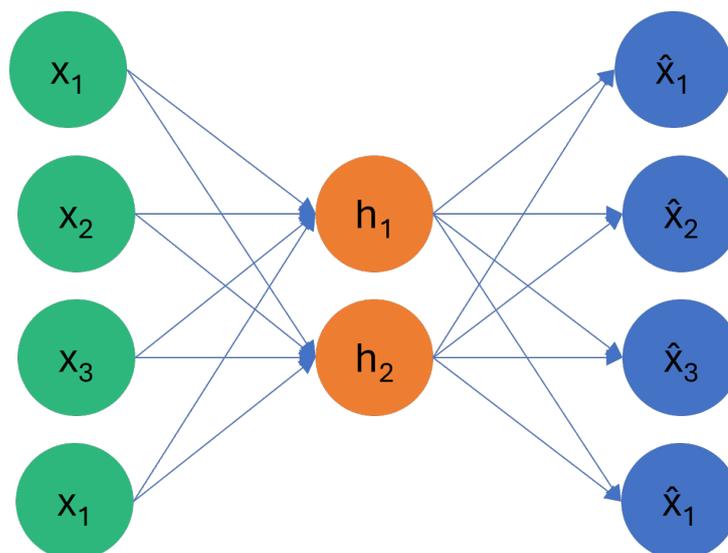


Figura 16 – Exemplo de um modelo de Rede Neural do tipo Autoencoder.

No contexto de redes convolucionais, existem os Autoencoders Convolucionais para o processamento de imagens 2D ou 3D. A estrutura do modelo é similar aos autoencoders tradicionais, porém, basicamente, substitui-se as camadas totalmente conectadas por camadas convolucionais, como ilustrado na Figura 17. A vantagem é que as características espacialmente correlacionadas podem ser aprendidas pelos Autoencoders Convolucionais, melhorando sua performance para, por exemplo, problemas de segmentação e extração de características de imagens (LONG; SHELHAMER; DARRELL, 2015).

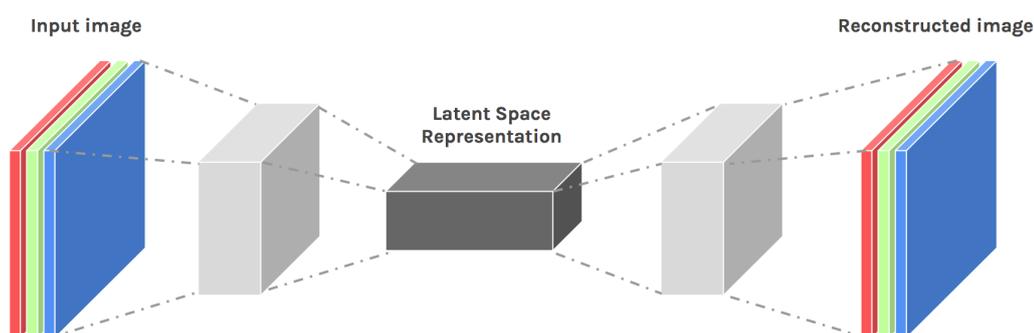


Figura 17 – Exemplo de um Autoencoder Convolucional (LONG; SHELHAMER; DARRELL, 2015).

2.4.3 Redes Neurais Generativas

Redes Neurais Generativas (RNG) são um grupo de redes neurais profundas que permitem a geração de amostras de dados que se assemelham aos dados originais em que foram treinadas (GOODFELLOW; BENGIO; COURVILLE, 2016). Esses modelos são capazes de aprender a capturar e reproduzir a distribuição estatística

dos dados de entrada, permitindo a criação de novas instâncias de dados que, embora sintéticas, são indistinguíveis dos dados reais. Entre elas, as Redes Adversárias Generativas (GANs) (GOODFELLOW; POUGET-ABADIE *et al.*, 2014) e os Autoencoders Variacionais (VAEs) (KINGMA; WELLING, 2019) têm sido objeto de estudos na literatura.

2.4.3.1 Variational Autoencoder

Os Variational Autoencoders (VAEs), ou Autoencoders Variacionais, (KINGMA; WELLING, 2019) são modelos de aprendizado de máquina que pertencem à categoria de modelos generativos. Eles são projetados para aprender representações latentes de dados complexos, como imagens, e são capazes de gerar novos dados a partir dessas representações. Ao contrário dos autoencoders tradicionais, os VAEs introduzem uma camada de probabilidade, modelando as representações latentes como distribuições, geralmente gaussianas, em vez de pontos fixos. Isso permite que os VAEs gerem novos dados que são variações dos dados de treinamento.

A arquitetura de um VAE é composta por duas partes principais: um encoder e um decoder. O encoder mapeia os dados de entrada para uma distribuição no espaço latente $q(z|x)$, que é geralmente uma distribuição gaussiana parametrizada por uma média μ e um desvio padrão σ . O decoder tenta reconstruir os dados de entrada a partir dessa representação latente $p(x|z)$. Durante o treinamento, os VAEs minimizam a diferença entre os dados originais e os dados reconstruídos, enquanto regularizam o espaço latente para garantir que ele tenha boas propriedades para a geração de novos dados.

A função de erro dos VAEs combina dois termos: a diferença de reconstrução, que mede a qualidade da reconstrução da imagem de entrada pelo decoder, e a divergência de Kullback-Leibler (KL), que regulariza a distribuição latente para que se aproxime de uma distribuição gaussiana padrão (KULLBACK; LEIBLER, 1951). A função de erro é expressa pela fórmula:

$$loss = -\mathbb{E}_{z \sim q(z|x)}[\log p(x|z)] + KL(q(z|x)||p(z)) \quad (7)$$

onde x é o dado de entrada e z é a informação do espaço latente reduzido gaussiano.

Após o treinamento, os VAEs podem gerar novas imagens a partir de amostras gaussianas, dadas por:

$$z \sim q(z|x) = \mathcal{N}(\mu, \sigma^2) \quad (8)$$

onde z pode ser utilizado como entrada do decoder para a geração de uma nova imagem. A Figura 18 ilustra a arquitetura de um Variational Autoencoder.

Uma das principais vantagens dos VAEs é a sua capacidade de gerar novas amostras que são variações dos dados de treinamento, o que é particularmente útil

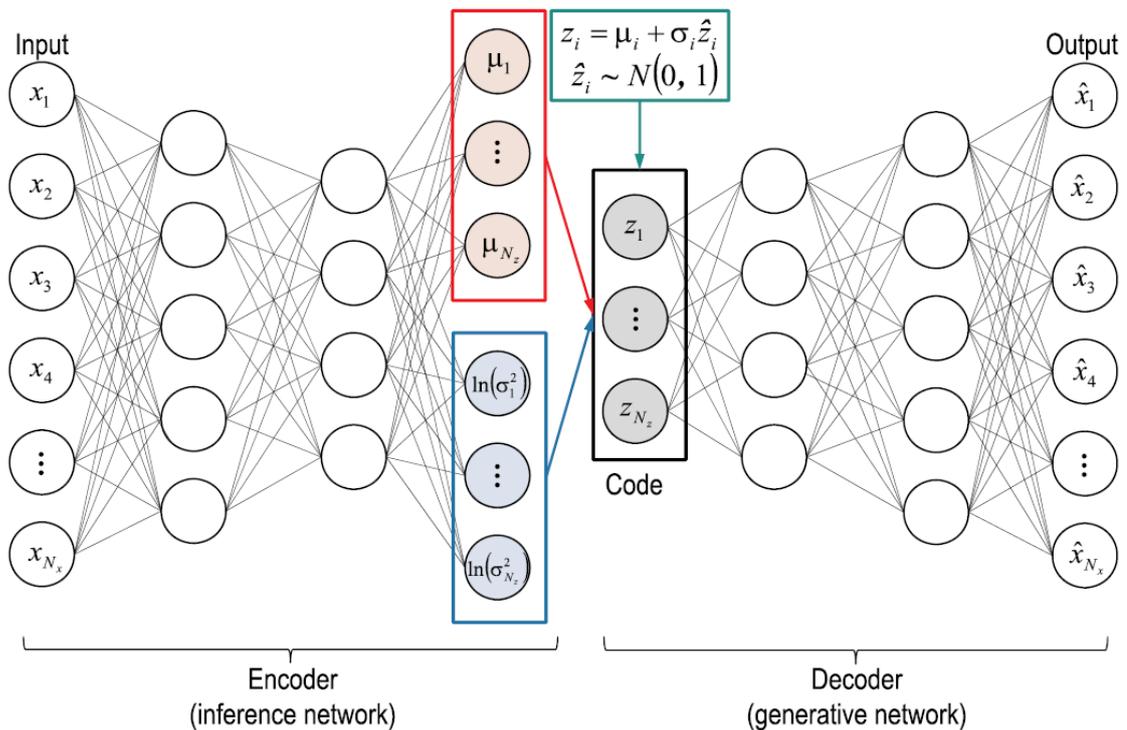


Figura 18 – Exemplo de um Variational Autoencoder adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016).

em tarefas como geração de imagens e redução de dimensionalidade. Além disso, a regularização imposta pela divergência de KL ajuda a garantir que o espaço latente seja suave e contínuo, permitindo uma interpolação significativa entre os pontos no espaço latente.

2.4.3.2 Generative Adversarial Network

Recentemente, Goodfellow, Pouget-Abadie *et al.* (2014) propuseram uma arquitetura chamada Redes Gerativas Adversárias (GANs), composta por dois modelos: o Gerativo (G) e o Discriminativo (D). O modelo Gerativo tenta gerar dados falsos que sejam indistinguíveis dos dados reais, enquanto o modelo Discriminativo tenta distinguir entre dados reais e falsos. A arquitetura de uma GAN é ilustrada na Figura 19.

Na proposta de Goodfellow, Pouget-Abadie *et al.* (2014), a arquitetura da Rede Gerativa Adversária é comparada a um jogo entre um falsificador (G), que tenta produzir dinheiro falso, e um policial (D), que tenta detectar o dinheiro falsificado. Essa competição leva ambos a aprimorar continuamente suas habilidades.

Formalmente, para que o modelo G obtenha a distribuição p_g a partir dos dados x , ele mapeia uma distribuição de ruído a priori $p_z(z)$ para $G(z; \theta_g)$. O modelo discriminativo $D(x; \theta_d)$ fornece a probabilidade de que uma amostra x gerada por G seja real.

Ambos os modelos, G e D, são treinados simultaneamente: os parâmetros de G

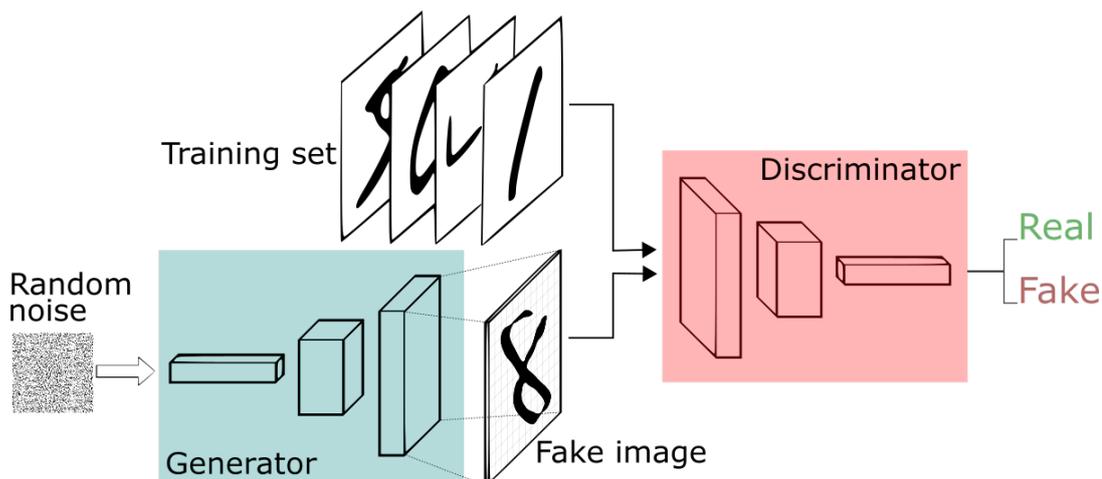


Figura 19 – Arquitetura das Redes Gerativas Adversárias. Adaptada de Goodfellow, Bengio e Courville (2016).

são ajustados para minimizar $\log(1 - D(G(z)))$ e os parâmetros de D são ajustados para minimizar $\log D(x)$. O processo de aprendizado pode ser expresso pela equação (GOODFELLOW; POUGET-ABADIE *et al.*, 2014):

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (9)$$

Na prática, segundo Goodfellow, Pouget-Abadie *et al.* (2014), a Equação 9 pode não fornecer um bom gradiente para que G aprenda satisfatoriamente. No início do treinamento, quando G não gera boas amostras, D pode rejeitá-las com alta confiança, fazendo com que $\log(1 - D(G(z)))$ saturar. Em vez disso, G pode ser treinado para maximizar $\log D(G(z))$, fornecendo gradientes melhores no início do treinamento.

Geralmente, uma GAN utiliza camadas totalmente conectadas para gerar dados a partir do modelo G. No entanto, Radford, Metz e Chintala (2015) adaptaram a proposta original da GAN para o contexto de imagens, propondo uma GAN com camadas convolucionais. Embora o conceito seja o mesmo, a GAN convolucional utiliza camadas convolucionais, que ajudam a gerar características de imagens espacialmente correlacionadas.

2.4.4 Transfer learning

Os modelos de aprendizagem profunda geralmente necessitam de grandes quantidades de dados para alcançar alto desempenho. No entanto, nem sempre é possível obter tantos dados para a maioria das tarefas de aprendizagem de máquina. Para contornar essa limitação, foram desenvolvidos métodos de transferência de aprendizado, ou transfer-learning, que permitem aos modelos de aprendizagem profunda atingirem alto desempenho mesmo com uma quantidade reduzida de dados (WEISS; KHOSHGOFTAAR; WANG, 2016; PAN; YANG, 2009).

O transfer-learning consiste em utilizar o conhecimento adquirido por uma rede neural pré-treinada com um determinado conjunto de dados, para classificação de imagens naturais, por exemplo, para resolver uma nova tarefa mais específica e que geralmente possui uma quantidade limitada de dados. Essa abordagem é baseada na ideia de que certas características e representações aprendidas pelas camadas convolucionais, principalmente, possam ser reaproveitadas para outras tarefas.

Uma técnica comum de transferência de aprendizado é o ajuste fino (*fine-tuning*) (TOO *et al.*, 2019), onde apenas algumas camadas da rede são treinadas, enquanto outras mantêm os pesos originais. Isso ajuda a adaptar a rede para problemas com poucos dados de treinamento e baixa variabilidade nas amostras, aproveitando o conhecimento prévio adquirido pela rede neural. Outra vantagem é a menor necessidade de recursos computacionais, pois como apenas algumas camadas são treinadas, reduzindo o poder de processamento necessário em comparação ao treinamento completo de uma rede neural profunda. A Figura 20 ilustra o conceito de transferência de aprendizado.

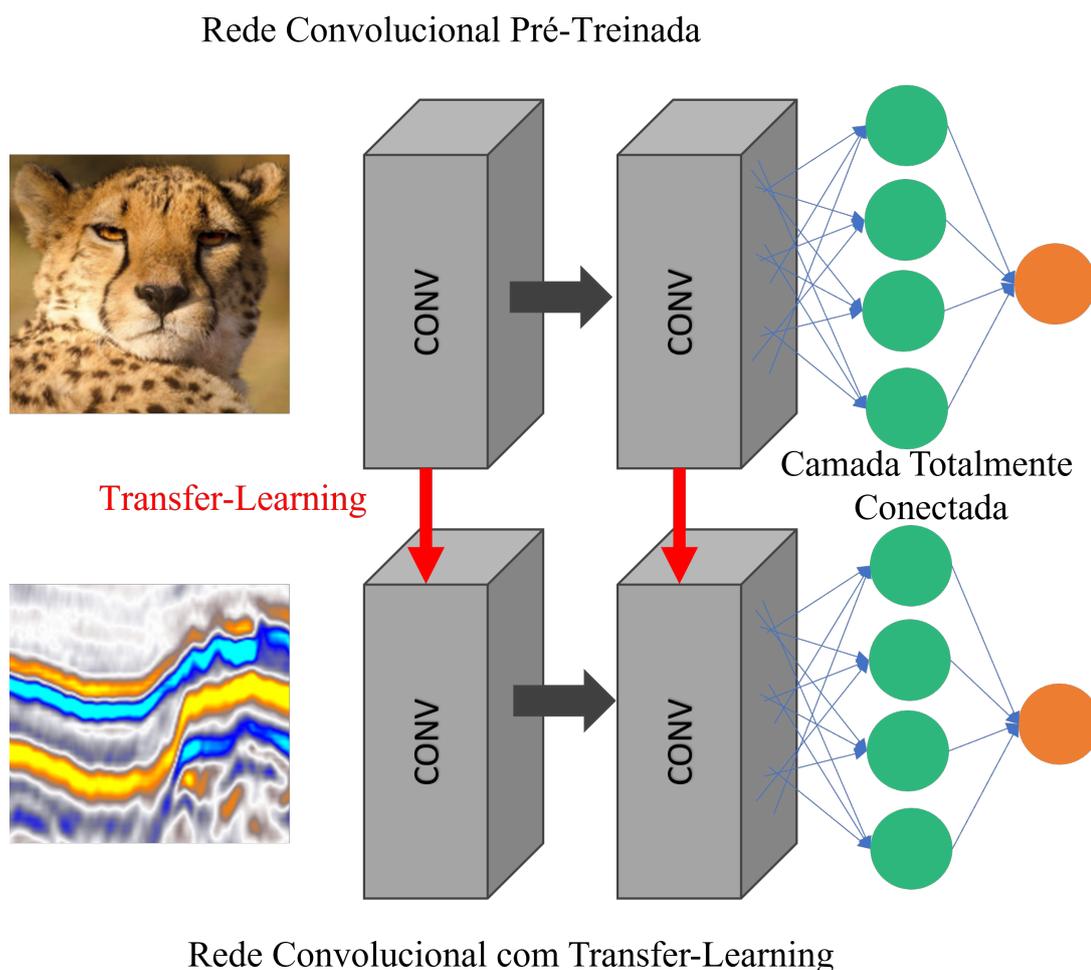


Figura 20 – Método de transferência de aprendizado para reaproveitamento dos pesos das camadas convolucionais para outro domínio de problema e treinando somente as camadas totalmente conectadas.

No contexto de caracterização e modelagem de reservatórios, em problemas inversos, como ajuste de histórico e inversão de fácies sísmicas, os dados sísmicos possuem grande quantidade de informações, mas são em sua maioria redundantes, ou seja, muitos dados são semelhantes. Esse cenário pode levar ao overfitting durante o treinamento de uma rede neural profunda, onde a rede se especializa nos dados de treinamento, mas não consegue generalizar bem para novos dados. Neste caso, com o transfer-learning é possível reutilizar redes treinadas com conjuntos de dados de alta variabilidade e adaptá-las para aplicações em problemas inversos. Isso melhora a capacidade da rede de generalizar e evita o overfitting, tornando a rede mais robusta e eficaz na resolução de problemas geocientíficos.

3 TRABALHO RELACIONADOS

Os problemas inversos são comumente abordados na área de geociências, na qual o Ensemble Smoother with Multiple Data Assimilation (ES-MDA) tem sido aplicado com sucesso para caracterização de reservatórios. No entanto, algumas limitações em relação à grande quantidade de dados, como o caso das sísmicas 4D e restrições no uso de dados discretos, levaram à pesquisa de métodos de redução dos dados observados e reparametrização das variáveis do modelo, para que o ES-MDA tenha melhor performance no processo de assimilação de dados e atualização dos modelos de reservatório. Atualmente, redes de aprendizado profundo têm sido integradas com ES-MDA para lidar com esses desafios.

Para a seleção de trabalhos correlacionados, primeiro, foi definido um escopo focado em problemas inversos em geociências, com ênfase na aplicação do Ensemble Smoother with Multiple Data Assimilation (ES-MDA) para a caracterização de reservatórios. Em seguida, foi feita a busca de estudos que abordaram os desafios relacionados à redução de dados observados, como as sísmicas 4D, e à reparametrização de variáveis discretas do modelo para melhorar o desempenho do ES-MDA em problema de inversão para fácies. Além disso, foi definida como prioridade a identificação de trabalhos recentes (últimos 5 anos) que integram redes de aprendizado profundo, como autoencoders e VAEs, no contexto da assimilação de dados geofísicos. Com isso, foi utilizada bases de dados como IEEE Xplore, ScienceDirect e Scopus, com palavras-chave relevantes, para refinar as buscas. Por fim, os artigos foram selecionados com base na relevância temática, impacto científico, inovação metodológica e soluções propostas para os desafios mencionados.

3.1 AJUSTE DE HISTÓRICO E ASSIMILAÇÃO DA SÍSMICA 4D

Para o problema de ajuste de histórico, onde os dados observados geralmente consistem em curvas de produção e sísmica 4D, um dos desafios está relacionado à grande quantidade de dados presentes nos volumes sísmicos, principalmente nas sísmicas 4D, adquiridas ao longo do ciclo produtivo do reservatório.

[Liu e Grana \(2018b\)](#) foram um dos primeiros a explorar a redução dos dados através de técnicas de decomposição em valores singulares (*Singular Value Decomposition* - SVD). O trabalho abordou o problema de ajuste de histórico para assimilar dados de produção, mas somente sísmica pós-processada, ou seja, apenas uma sísmica para o mesmo reservatório, sem o uso da sísmica 4D. Além disso, de acordo com o trabalho, foram feitos vários testes para definir os melhores parâmetros para o ES-MDA, como a quantidade de iterações e parâmetros do SVD. No entanto, alguns problemas foram reportados, como a baixa quantidade de iterações: somente três iterações foram possíveis, sendo que com uma quantidade maior, o ES-MDA colapsava

para uma única solução, tornando a análise da incerteza superestimada. Sobre os parâmetros do SVD, apenas 50 valores foram escolhidos, sendo que uma quantidade maior não melhorava o resultado da inversão. Por fim, a proposta foi testada em um dado sintético 2D, não sendo aplicada para dados tridimensionais.

Mais tarde, [Liu e Grana \(2020\)](#) propuseram uma metodologia para reduzir a quantidade de dados de produção e sísmica 4D para a predição de modelos de reservatórios. Utilizando o ES-MDA, os autores propuseram o uso de autoencoders convolucionais para reduzir a dimensionalidade dos dados sísmicos através da extração de características espacialmente correlacionadas. Ao invés de utilizar todo o conjunto de dados de sísmica 4D, utiliza-se apenas as características extraídas no ES-MDA. Neste caso os dados de sísmica observada e simulada são submetidas ao autoencoder e as características extraídas são utilizadas em alternativa aos dados sísmicos no cálculo das matrizes de covariância. A proposta foi testada em dois casos sintéticos, 2D e 3D. Apesar da metodologia proposta ser promissora, o autoencoder convolucional, ilustrado na Figura 21, foi treinado utilizando os próprios dados de sísmica 4D, sendo necessário um novo treinamento para outros campos com reservatórios de características distintas.

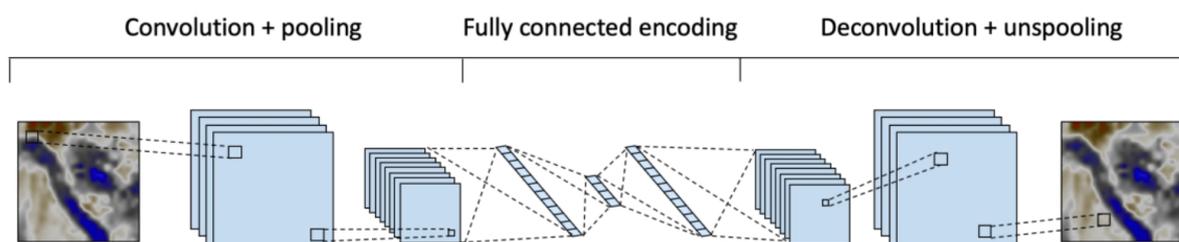


Figura 21 – Autoencoder convolucional utilizado para redução da sísmica 4D. Adaptado de [Liu e Grana \(2020\)](#).

Recentemente, muitos modelos pré-treinados têm sido disponibilizados em repositórios públicos, projetados para um problema específico, mas adaptados para outros domínios. A ideia é reutilizar a parte de extração de características de um modelo pré-treinado, assumindo que as características de imagem (linhas, bordas, curvas, etc.) são úteis em qualquer caso. Além disso, como os pesos já estão otimizados, o modelo pré-treinado converge rapidamente com um pequeno conjunto de dados. Esse tipo de abordagem pode ser benéfico para a aplicação na caracterização de reservatórios, já que os dados sísmicos de monitoramento também podem ser interpretados como imagens regulares. Em termos de aplicações em geociências, [\(BAMNE et al., 2020\)](#) adaptaram o modelo VGG-19 para aplicação em detecção de objetos, [\(WEN et al., 2019\)](#) para diagnóstico de falhas em reservatórios, [\(LIU; DURLOFSKY, 2020\)](#) para parametrização geológica e [\(ALQAHTANI et al., 2021\)](#) para caracterização baseada em fluxo através do método de aprendizado por transferência.

Além disso, estudos mostram que, ao invés de utilizar diretamente o dado sísmico

e refletividade, outros atributos podem ser substitutos para este dado. De acordo com [Fahimuddin, Aanonsen e Skjervheim \(2010\)](#), a diferença da propriedade elástica impedância-P, obtida para cada aquisição sísmica, se mostrou mais adequada e com a melhor performance para o caso de ajuste de histórico.

3.2 INVERSÃO DE FÁCIES SÍSMICAS

A aplicação do ES-MDA para problemas de inversão de fácies sísmicas tem como desafio a utilização de dados discretos, como é o caso das fácies, que representam classes de diferentes tipos de rochas. Isso exige o uso de técnicas de reparametrização desses dados para o espaço contínuo. Além disso, o ES-MDA pressupõe que as variáveis do modelo sejam representadas ou geradas a partir de amostras gaussianas.

[Grana \(2016\)](#) relatam que, no caso das inversões estocásticas propostas recentemente, geralmente se faz uma linearização do modelo forward para que o custo computacional seja menor. Neste caso, é necessário assumir que os parâmetros dos modelos, ou seja, as propriedades e os erros possuem a forma de distribuições Gaussianas. No entanto, essas premissas podem causar problemas em certas situações, como, por exemplo, para aquisições sísmicas com ângulos muito elevados ou em domínios de física de rochas altamente não lineares que relacionam as propriedades elásticas com as petrofísicas.

[Figueiredo, Rodrigues et al. \(2019\)](#) propuseram uma metodologia denominada BELFI (Bayesian Seismic Inversion for the Joint Estimation of Facies and Elastic Properties) onde assume-se que as variáveis do modelos possam ser amostradas a partir de distribuições gaussianas utilizando $p(m|k)$, onde k representa as fácies a serem amostradas. No entanto, o *forward model* para a simulação da sísmica a partir das fácies foi linearizado, reduzindo assim o espaço de busca da solução. Além disso, não houve exploração de redes neurais profundas para reduzir a quantidade de dados e não foi utilizado o ES-MDA, pois se tratava de uma proposta alternativa.

Já em problemas de inversão não lineares, não existe uma fórmula direta para a solução, sendo necessário adaptar métodos numéricos como Monte Carlo para amostrar a distribuição *a posteriori*. No entanto, em problemas de grande dimensionalidade, estes métodos podem rejeitar muitas amostras e acabam não fornecendo resultados satisfatórios ([FIGUEIREDO; RODRIGUES et al., 2019](#)).

Um dos primeiros trabalhos de integração de aprendizado profundo com ES-MDA para reparametrização das fácies foi explorada por ([CANCHUMUNI, S. A.; EMERICK; PACHECO, M. A., 2017](#)). Os autores focaram na correspondência histórica para estimar os parâmetros de fácies de reservatório, que representam m . Essas fácies são reparametrizadas em um espaço de menor dimensão z usando autoencoders profundos consistindo em camadas totalmente conectadas. A escolha de autoencoders é baseada em seu papel percebido como uma extensão não linear da Análise de Com-

ponentes Principais (PCA), conforme discutido em (ALMOTIRI; ELLEITHY; ELLEITHY, 2017). Os resultados demonstram melhorias notáveis no tempo de processamento em comparação com métodos anteriores baseados em PCA (EMERICK, 2017). No entanto, o estudo apresenta algumas limitações, especialmente em cenários de fâcies de baixa dimensão e binárias, devido a desafios no treinamento do autoencoder e ao alto número de pesos treináveis em aplicações 2D e 3D. Além disso, não foram utilizadas redes neurais convolucionais, ideal para processamento de dados em formato 2D ou 3D, como discutido anteriormente.

Mais tarde, (CANCHUMUNI, S. W.; EMERICK; PACHECO, M. A. C., 2019) propuseram substituir o autoencoder por Variational Autoencoders (VAE). Tradicionalmente, os VAEs são um tipo de modelo gerativo que emprega uma mistura de camadas convolucionais e totalmente conectadas, onde a representação latente z é derivada de amostras gaussianas. Apesar dos avanços, a aplicação de métodos baseados em localização de distância apresentou novos desafios na metodologia, por exemplo, com a perda de correlação espacial causada pelas camadas totalmente conectadas em z , que não conseguem obter a estrutura espacial e a captura de dependências locais em dados de imagem. A arquitetura da VAE utilizada por Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019) é ilustrada na Figura 22.

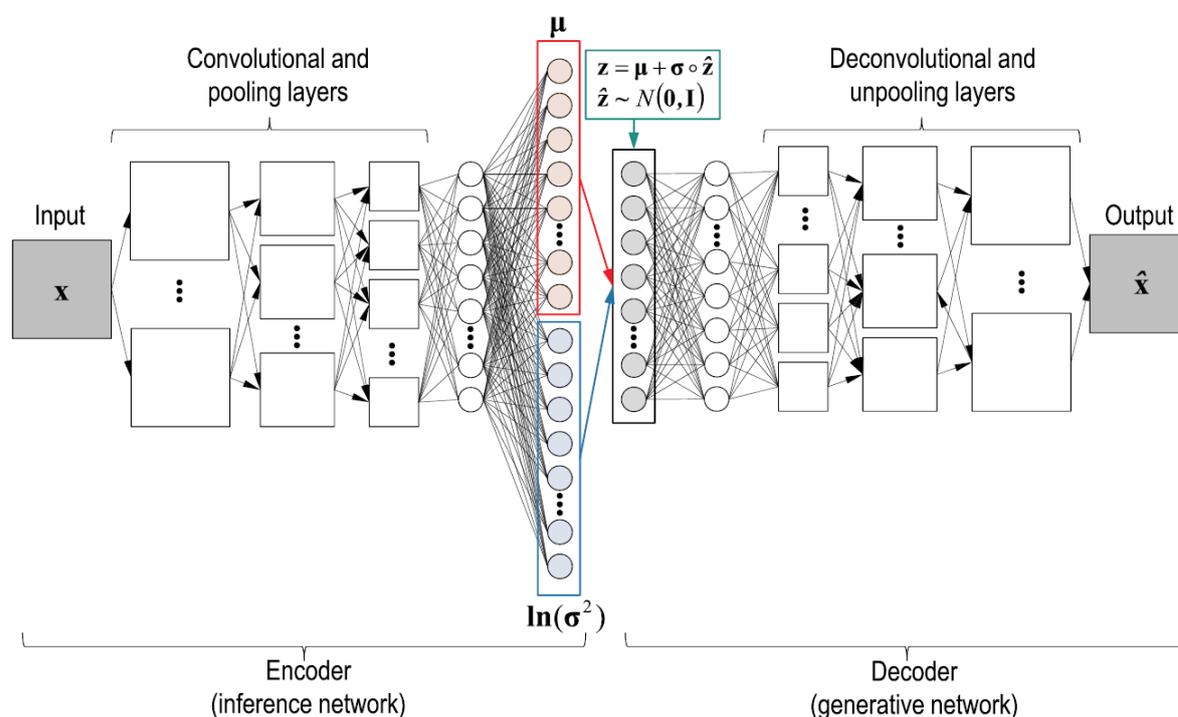


Figura 22 – Variational Autoencoder com camadas convolucionais utilizada no trabalho de Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019).

Os autores fizeram dois testes em casos sintéticos 2D e posteriormente um teste com modelos de fâcies 3D. No primeiro teste, a VAE foi treinada com 24.000 realizações de fâcies geradas pela solução **snesim**, utilizando uma mesma imagem de

treinamento como referência, e a validação foi feita com 6.000 realizações adicionais. Cada modelo de reservatório gerado pelo *snemim* possui duas fácies: 1 para canais com permeabilidade de 5.000 mili-darcy (mD) e 0 para canais com permeabilidade de 500 (mD). A Figura 23 ilustra o processo de treinamento da VAE.

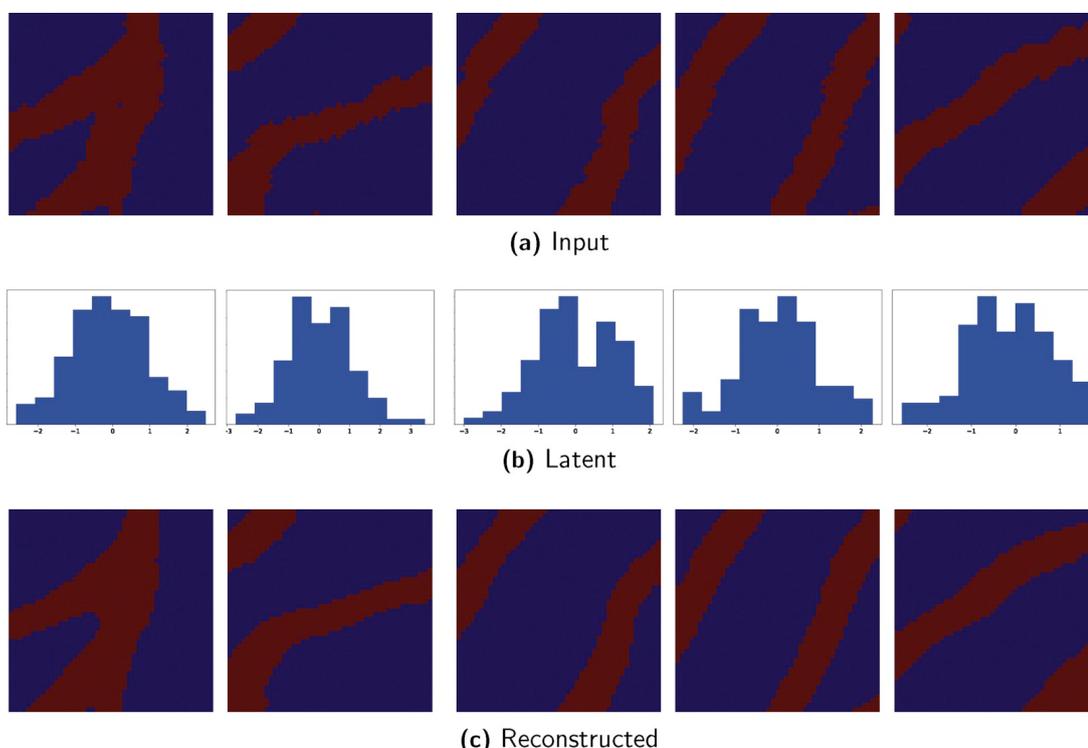


Figura 23 – Etapa de treinamento e o espaço latente da VAE para cinco realizações de fácies do conjunto de validação. Adaptada de [Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco \(2019\)](#).

Para o último teste com modelos 3D e três fácies (canal, dique e areia), [Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco \(2019\)](#) utilizaram VAE com camadas convolucionais 3D, aumentando o tempo de treinamento da rede. Porém, apesar dos resultados promissores, a acurácia no processo de reconstrução foi inferior, apresentando características que não estavam presentes no conjunto de modelos geológicos *a priori*. Como trabalho futuro, os autores propõem a utilização das Generative Adversarial Nets para melhorar o processo de reconstrução em modelos 3D.

Entretanto, a metodologia proposta por [Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco \(2019\)](#) utiliza VAE com camadas totalmente conectadas no espaço latente da rede. Com isso, a correlação espacial das informações obtidas pelas camadas convolucionais durante o treinamento é perdido, gerando problemas para a questão da localização. Este problema também é abordado no mais recente trabalho de [Canchumuni et al. \(2021\)](#), onde no trabalho contém uma revisão de diversos tipos de modelos generativos combinados com ES-MDA para ajuste de histórico. São eles: Variational Autoencoder, Generative Adversarial Nets, Wasserstein GAN ([ARJOVSKY; CHINTALA; BOTTOU, 2017](#)), Auto-Encoding GAN ([ROSCA et al., 2017](#)), Cycle-GAN

(ZHU *et al.*, 2017) e Transfer Style Networks (GATYS; ECKER; BETHGE, 2016).

A utilização de rede neurais compostas por camadas totalmente conectadas possuem certas limitações para o contexto do problema de localização que geralmente são utilizados no Ensemble Smoother. Isto se dá pelo fato de que não é possível aplicar métodos de localização baseados em distância (HOUTEKAMER; MITCHELL, 2001), pois o vetor \mathbf{z} está em uma espaço diferente em relação aos dados originais. Portanto, para aplicações em ajuste de histórico, não faz sentido calcular uma distância euclidiana entre um componente de \mathbf{z} com a posição espacial do poço perfurado.

Para contornar esta limitação, Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019) utilizam a quantidade de neurônios no espaço latente sendo a mesma quantidade de blocos do grid do reservatório. No entanto, mesmo assim os autores relataram que não teriam certeza se existe uma relação direta entre o vetor \mathbf{z} com a localização espacial destes blocos. Os autores assumiram que, como os parâmetros das camadas convolucionais são compartilhadas, cada componente de \mathbf{z} talvez esteja associada com a reconstrução das fácies para cada região diferente do reservatório, ou seja, os mesmos pesos dos *kernels* são aplicados a múltiplas regiões dos dados de entrada. Além disso, à medida que a camada latente cresce, os parâmetros da rede crescem significativamente devido às camadas totalmente conectadas. Na prática, Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019) mencionam que utilização de camadas totalmente conectadas com muitos neurônios tornam a aplicação desta metodologia inviável para grandes modelos de reservatórios.

Existem algumas abordagens para o problema de localização (LACERDA; EMERICK; PIRES, 2019), entretanto não estão formuladas em termos da distância espacial que poderiam ser aplicadas neste caso. Infelizmente, de acordo com Smith WA Canchumuni, Emerick e Marco Aurélio C Pacheco (2019), estas abordagens são menos efetivas do que métodos de dependência entre distâncias. Portanto, o problema de localização utilizando redes neurais para reparametrização das fácies ainda é um problema em aberto.

4 METODOLOGIA PROPOSTA

Neste capítulo, objetivo é apresentar a metodologia proposta neste trabalho para a integração de redes neurais profundas com Ensemble Smoother with Multiple Data Assimilation, com foco em problemas de ajuste de histórico com a assimilação sísmica 4D e inversão de fácies sísmicas com a assimilação de sísmica pós-processada 2D com reparametrização das fácies.

4.1 AUTOENCODER E ES-MDA PARA AJUSTE DE HISTÓRICO

Para o problema inverso de ajuste de histórico, os trabalhos propostos com ES-MDA tiveram grande sucesso, principalmente alguns dos mais recentes que realizaram a integração do ES-MDA com redes autoencoders para a redução dimensional dos dados sísmicos. Porém, as principais limitações das propostas é o de um retreinamento de toda a rede neural autoencoder para cada caso de reservatório diferente e algumas delas eram limitadas em casos 2D.

Neste trabalho, a proposta é utilizar Autoencoder para a redução dimensional das sísmicas 4D. A principal inovação é que o Autoencoder proposto é baseado em redes pré-treinadas a partir de imagens naturais, na qual permitem realizar o *transfer-learning*, um ajuste fino na camada mais interna do Autoencoder para aumento da performance da rede em imagens de sísmica. Para o ajuste de histórico foram desenvolvidos dois Autoencoders, o Autoencoder 2D e Autoencoder 3D.

4.1.1 Autoencoder 2D

No Autoencoder 2D, a arquitetura da rede é baseada na VGG-19 (SIMONYAN; ZISSERMAN, 2014), que é uma rede neural convolucional com 19 camadas convolucionais, que originalmente foi treinada para classificação de 1000 objetos utilizando o conjunto de dados ImageNet (DENG *et al.*, 2009). No entanto, os pesos das camadas convolucionais da VGG-19 podem ser reaproveitados para outros propósitos, como a reutilização para a extração de características das imagens de entrada através da técnica de *transfer-learning*.

As camadas convolucionais da VGG-19 são utilizadas como *encoder* e com base nestas camadas, foi desenvolvido uma estrutura inversa que representa o *decoder*, que tem como tarefa reconstruir a imagem de entrada da rede. Portanto, a ideia é reaproveitar os pesos das camadas convolucionais selecionadas da VGG-19 e utilizar o *decoder* para fazer um ajuste fino em qualquer camada da rede, principalmente nas camadas mais latentes. Com isso, é possível obter uma melhor adaptação do autoencoder proposto para o caso de processamento das sísmicas 4D.

A VGG-19 original possui na sua última camada convolucional latente 512 filtros

pré-treinados e extrai ao total de 512 mapas de características de um determinado tamanho reduzido a partir de uma única imagem de entrada. Por exemplo, para imagem de tamanho 128×128 , com 16.128 pixels, são extraídos 512 mapas de características de tamanho 8×8 , totalizando 32.768 pontos. Porém, para o problema de ajuste de histórico com ES-MDA, o objetivo é reduzir a quantidade de dados, e não aumentar. Portanto, a proposta deste trabalho é a adição de uma camada convolucional latente entre a VGG-19 encoder e a estrutura decoder com somente 1 filtro convolucional. Essa estrutura latente faz com de uma imagem 2D de 128×128 seja extraída somente 1 mapa de característica de tamanho 32×32 , reduzindo em até 93% da quantidade de dados da entrada. A Tabela 1 descreve a estrutura e as camadas compostas pelo autoencoder 2D desenvolvido neste trabalho.

Tabela 1 – Autoencoder 2D proposta neste trabalho.

		Layer	Strides	Filters	Activation
1	Encoder (VGG-19)	Conv2D	1	64	ReLU
2		Conv2D	1	64	ReLU
3		MaxPooling	-	-	-
4		Conv2D	1	128	ReLU
5		Conv2D	1	128	ReLU
6		MaxPooling	-	-	-
7		Conv2D	1	256	ReLU
8		Conv2D	1	256	ReLU
9		Conv2D	1	256	ReLU
10		Conv2D	1	256	ReLU
11	Latent	Conv2D	1	1	ReLU
12		Conv2D	1	256	ReLU
13	Decoder	Conv2D	1	256	ReLU
14		Conv2D	1	256	ReLU
15		Conv2D	1	256	ReLU
16		Conv2D	1	256	ReLU
17		Conv2DTranspose	2	256	ReLU
18		Conv2D	1	128	ReLU
19		Conv2D	1	128	ReLU
20		Conv2DTranspose	2	128	ReLU
21		Conv2D	1	64	ReLU
22		Conv2D	1	64	ReLU
23		Conv2D	1	3	ReLU

Normalmente, um reservatório possui sua estrutura modelada em 3D. Neste caso, para o funcionamento do Autoencoder 2D, é utilizada cada camada da direção topo-base como uma imagem 2D. Por exemplo, para uma reservatório 3D de dimensão $128 \times 128 \times 64$, é extraída 64 imagens (última dimensão) de tamanho 128×128 . Aqui, assume-se que imagens semelhantes possuem características semelhantes, ou seja, neste trabalho as camadas das sísmicas 4D semelhantes terão características também muito parecidas.

4.1.2 Autoencoder 3D

No Autoencoder 3D, foi desenvolvido uma arquitetura de rede própria, treinada com dados tridimensionais encontrados na literatura e posteriormente também ajustada para as sísmicas 4D. A principal diferença do Autoencoder 3D proposto é que as camadas convolucionais 3D foram definidas para reduzir somente duas dimensões dos dados de entrada para o espaço latente. Este controle se deu por uma configuração específica do *stride*.

Na literatura também é possível encontrar redes neurais 3D treinadas para o uso de *transfer-learning*. Porém, geralmente os filtros convolucionais 3D são configurados para aprender e reduzir o volume de entrada nas três dimensões, ou seja, utilizando o mesmo *stride* para todas as dimensões do volume. Neste trabalho, foi desenvolvido uma nova arquitetura de autoencoder 3D para que somente duas dimensões do volume de entrada, altura e largura. Com isso, pode-se preservar a profundidade do volume para que as características extraídas do dado de entrada seja compatível às dimensões das características do Autoencoder 2D. Isso faz com que o Autoencoder 3D extraia a mesma quantidade e dimensão de características do que um Autoencoder 2D, porém utilizando filtros tridimensionalmente correlacionado. No caso do exemplo de um volume $128 \times 128 \times 64$, ao final se tem um redução para uma característica latente de $32 \times 32 \times 64$.

A arquitetura do Autoencoder 3D proposta neste trabalho é composta por um encoder 3D com 12 camadas convolucionais e um decoder 3D com 13. A função de ativação ReLU foi utilizada em todas as camadas convolucionais. A Tabela 2 descreve a arquitetura do Autoencoder 3D proposta neste trabalho.

A ideia da compatibilidade de dimensão das características extraídas entre o Autoencoder 2D e 3D se dá pelo fato da possibilidade e adaptar as técnicas de localização de covariância para as informações latentes da rede neural. Outro aspecto importante é que o Autoencoder preserva a relação espacial nas entradas no espaço latente, onde uma região de imagem de entrada tem uma região correspondente no mapa de características latentes.

4.1.3 Proposta para Ajuste de Histórico

As principais diferenças da metodologia proposta neste trabalho em relação ao estado da arte são: o Autoencoder pré-treinando com imagens naturais, uso da técnica *transfer-learning* e a representação latente do autoencoder totalmente convolucional com apenas um filtro. Essa capacidade permite o uso de técnicas de localização aplicadas no ES-MDA diretamente em recursos extraídos de lapso de tempo sísmico. Para simplificar, reduzimos a matriz R para uma dimensão inferior e produzimos uma dimensão compatível na multiplicação $R \circ \tilde{K}$.

Em ambos os autoencoders totalmente convolucionais propostos, uma entrada de

Tabela 2 – Autoencoder 3D proposta neste trabalho.

		Layer	Strides	Filters	Activation
1	Encoder	Conv3D	1	32	ReLU
2		Conv3D	(2,2,1)	32	ReLU
3		Conv3D	1	64	ReLU
4		Conv3D	(2,2,1)	64	ReLU
5		Conv3D	1	128	ReLU
6		Conv3D	1	128	ReLU
7		Conv3D	1	128	ReLU
8		Conv3D	1	128	ReLU
9	Latent	Conv3D	1	1	ReLU
10		Conv3D	1	128	ReLU
11	Decoder	Conv3DTranspose	1	128	ReLU
12		Conv3DTranspose	1	128	ReLU
13		Conv3DTranspose	1	128	ReLU
14		Conv3DTranspose	1	128	ReLU
15		Conv3DTranspose	(2,2,1)	64	ReLU
16		Conv3DTranspose	1	64	ReLU
17		Conv3DTranspose	(2,2,1)	32	ReLU
18		Conv3DTranspose	1	32	ReLU
19		Conv3DTranspose	1	1	ReLU

imagem é reduzida para aproximadamente 90% ou 16 vezes menos pontos de dados em comparação com o tamanho original. A ideia é simplificar através das características latentes e reduzir a informação para o processamento do ES-MDA. Considerando os dados sísmicos observados d_{obs} e simulados $g(m^k)$, ambos serão codificados em características extraídas z . Portanto, os dados d serão representados como $z = AE(d)$, sendo AE o Autoencoder 2D ou 3D. Como resultado, a matriz de cross-covariância entre os parâmetros do modelo m e as características extraídas z dos dados d pode ser reescrita como C_{mz} e a auto-covariância como C_{zz} com uma dimensão esperada 16^2 menor, reduzindo a demanda por recursos computacionais. Sendo assim, a formulação original do ES-MDA pode ser reescrita como:

$$m_j^{k+1} = m_j^k + C_{mz}^k (C_{zz}^k + \alpha_k C_e)^{-1} (z_{obs,j}^k - z_{sim,j}^k) \quad (10)$$

para $j = 1, \dots, N_a$ sendo N_e o tamanho do ensemble, $z_{sim} = AE(g(m_j))$ a representação latente dos dados simulados e $z_{obs} = AE(d_{obs})$ a representação latente dos dados observados, com $C_e \in \mathbb{R}^{N_d \times N_d}$ sendo a matriz de covariância do erro dos dados, $g(m_j^k)$ é o conjunto de dados simulados. Portanto, as matrizes de covariância $C_{mz} \in \mathbb{R}^{N_m \times N_z}$ e $C_{zz} \in \mathbb{R}^{N_z \times N_z}$ são obtidas durante cada iteração do processo de atualização feita no ES-MDA.

Esta metodologia proposta de ES-MDA com integração do Autoencoder para ajuste de histórico, ilustrada na Figura 24, consiste em cinco etapas principais, conforme segue:

1. Ajuste fino do modelo Autoencoder com dados sísmicos de lapso de tempo observáveis;
2. Geração das realizações iniciais do conjunto $m_j^{k=0}$;
3. Utilizar o encoder para redução do dado simulado $z_{sim,j}^k = AE(g(m_j^k))$ e o dado observável $z_{obs,j} = AE(d_{obs,j}^k)$;
4. Reduzir a matriz de localização R na ordem de z ;
5. Calcular o ganho de Kalman \tilde{K} com C_{mz} e C_{zz} reduzidos;
6. Aplique o ES-MDA para atualizar m^{k+1} ;
7. Execute o *forward model* $g(m^{k+1})$ com parâmetros atualizados;
8. Repita 3 até 7 de acordo com o número de iterações N_a .

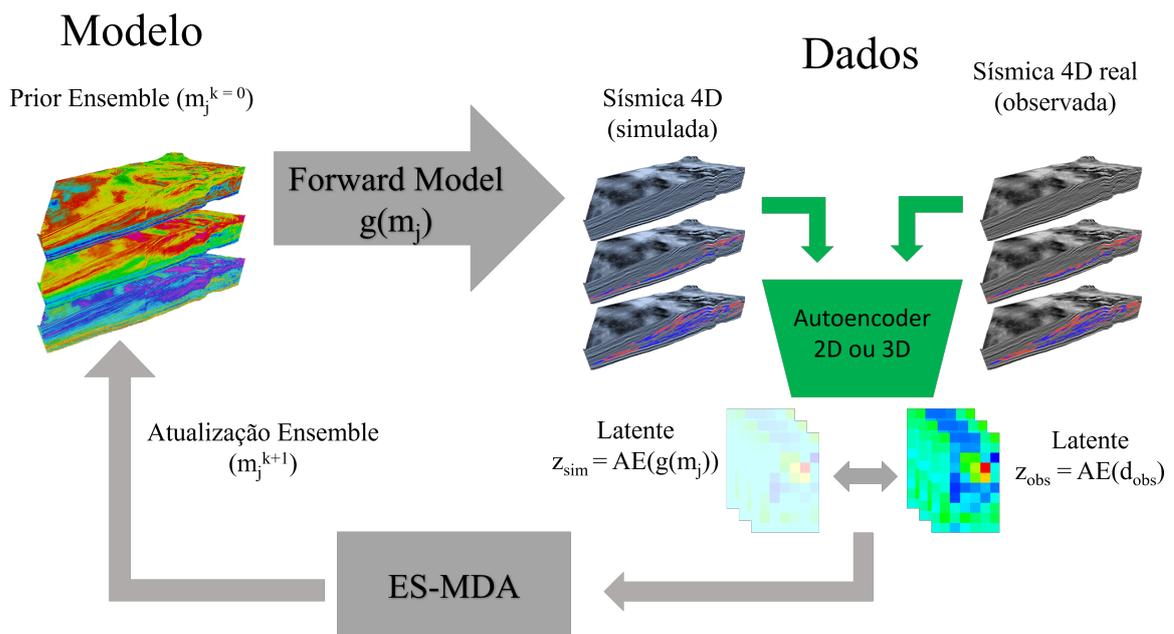


Figura 24 – Proposta deste trabalho para ajuste de histórico com ES-MDA integrado com Autoencoder como um extrator de características dos dados observados e simulados.

Dentre as vantagens da metodologia proposta está principalmente na utilização de autoencoders pré-treinados com imagens naturais e a aplicação de transfer-learning para a adaptação da rede neural profunda para a extração de características das Sísmicas 4D. A Tabela 3 compara os métodos apresentados e discutidos anteriormente com a proposta deste trabalho para ajuste de histórico.

	Ajuste de Histórico com ES-MDA e Sísmica 4D	LC	Redução da Sísmica 4D	AE	Transfer learning
Emerick (2013)	✓	✓			
Luo et al. (2018)	✓		✓		
Liu e Grana (2020)	✓		✓	✓	
Este trabalho	✓	✓	✓	✓	✓

LC - Localização da Covariância

AE - Autoencoder

Tabela 3 – Comparação dos trabalhos relacionados com a proposta deste trabalho para ajuste de histórico com sísmica 4D.

4.2 REDES GENERATIVAS E ES-MDA PARA INVERSÃO DE FÁCIES SÍSMICAS

Inspirado pelos trabalhos de [Alexandre A Emerick e Albert C Reynolds \(2013a\)](#), [Goodfellow, Pouget-Abadie et al. \(2014\)](#), [Liu e Grana \(2018b\)](#), [Grana \(2018\)](#) e [Figueiredo, Rodrigues et al. \(2019\)](#) a proposta deste trabalho é explorar modelos generativos integrados ao ES-MDA para o problema de inversão de fácies sísmicas. A abordagem envolve uma transformação das fácies discretas para um espaço contínuo com dimensionalidade reduzida.

Neste trabalho, foram exploradas duas redes generativas: Variational Autoencoder e Generativa Adversarial Net. Diferente dos trabalhos relacionados que utilizaram redes generativas, mas com arquiteturas mistas de camadas convolucionais e totalmente conectadas, neste trabalho foi utilizada arquitetura totalmente convolucional. Esta arquitetura permite que o espaço latente esteja espacialmente correlacionado, o que faz com que cada ponto do espaço latente represente uma região da imagem de entrada. Essa premissa é a mesma ideia dos autoencoders explorados na seção anterior. Com isso, futuras aplicações com a localização de covariância serão também compatíveis com essa abordagem.

4.2.1 Variational Autoencoder

A primeira rede generativa proposta neste trabalho é um Variational Autoencoder 2D para a reparametrização das fácies do espaço discreto para o contínuo. A ideia é que modelos de fácies, que são os parâmetros do modelo de reservatório a serem estimados, possam ser representados a partir de amostras gaussianas do espaço latente reduzido, onde se utiliza o decoder para a reconstrução das mesmas, integrado com ES-MDA.

O Variational Autoencoder proposto possui 15 camadas, sendo 7 na estrutura do encoder e 7 no decoder, somadas às camadas latentes utilizadas para a regularização do espaço reduzido às amostras gaussianas. O espaço latente é composto por duas camadas denominadas z_{mean} , que representa a média da distribuição gaussiana do

espaço latente, e z_{log_var} , que é responsável pela estabilidade durante o treinamento, assegurando que a variância sempre seja positiva. Em ambas, foi utilizada uma camada convolucional somente com 3 *kernels*, de modo que a informação latente z , em vez de ser um vetor como na camada densa, agora será uma matriz.

A estrutura da VAE é composta somente por camadas convolucionais, diferente das tradicionais encontradas na literatura. Com isso, o tamanho dos dados de entrada durante o treinamento não precisa ser o mesmo no momento da reconstrução, ou seja, a rede pode ser treinada com imagens de tamanho 128×128 e ser aplicada em imagens de tamanhos maiores, como 256×256 , ou ainda menores, como 64×64 . A Tabela 4 ilustra a arquitetura da VAE proposta neste trabalho.

		Layer	Strides	Filters	Activation
1	Encoder	Conv2D	(1,1)	32	ReLU
2		Conv2D	(1,1)	32	ReLU
3		Conv2D	(2,2)	64	ReLU
4		Conv2D	(1,1)	64	ReLU
5		Conv2D	(2,2)	128	ReLU
6		Conv2D	(1,1)	128	ReLU
7	z_mean	Conv2D	(1,1)	3	-
8	z_log_var	Conv2D	(1,1)	3	-
9	Decoder	Conv2DTranspose	(1,1)	128	ReLU
10		Conv2DTranspose	(2,2)	128	ReLU
11		Conv2DTranspose	(1,1)	64	ReLU
12		Conv2DTranspose	(2,2)	64	ReLU
13		Conv2DTranspose	(1,1)	32	ReLU
14		Conv2DTranspose	(1,1)	32	ReLU
15		Conv2DTranspose	(1,1)	4	Sigmoid

Tabela 4 – Arquitetura da VAE utilizada nos experimentos deste trabalho.

Após treinada, a parte do decoder da VAE irá reconstruir a imagem original a partir do espaço reduzido z . Neste caso, a entrada do decoder será a informação do filtro da camada convolucional latente que representa a média z_{mean} . Após treinada, a VAE consegue reproduzir e gerar novas imagens a partir de amostras gaussianas. Além disso, a ideia é poder representar as fâcias com até 94% menos informações dependendo da dimensão original dos dados de entrada e saída. Portanto, utilizando somente o espaço latente reduzido da VAE é possível ganhar performance e realizar a reparametrização das fâcias no processo de inversão, pois menos informação serão processadas. A Figura 25 ilustra o processo de treinamento da VAE com fâcias.

4.2.2 Generative Adversarial Net

A rede Generativa Adversarial Net tem finalidade semelhante às Variational Autoencoders, porém sua estrutura e forma de treinamento são diferentes. No caso da GAN, a arquitetura possui duas redes: a Geradora e a Discriminadora.

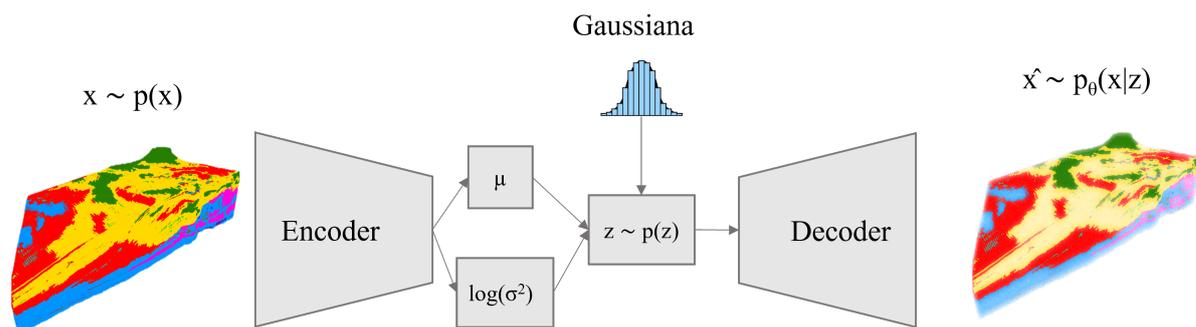


Figura 25 – Treinamento para geração de fácies utilizando VAE.

Na Geradora, a estrutura original de [Goodfellow, Pouget-Abadie et al. \(2014\)](#) relaciona o vetor latente z como a entrada da rede, sendo ela uma camada totalmente conectada. Neste trabalho, a entrada z da rede Geradora também foi alterada por uma camada convolucional transposta, com 3 filtros somente, fazendo com que z seja matriz e não vetor. A ideia é que a partir de uma entrada aleatória gaussiana se mantenha a correlação espacial e a partir dela as camadas convolucionais transpostas são responsáveis por aumentar a dimensão de z e gerar a imagem final.

Para a rede Discriminadora, foram utilizadas 3 camadas convolucionais e, como D é um classificador, a última camada é totalmente conectada, que irá classificar se a imagem gerada por G é verdadeira ou falsa. Neste caso, como D é utilizado apesar para treinamento, não houve grandes mudanças em relação à proposta original de [Goodfellow, Pouget-Abadie et al. \(2014\)](#). A Tabela 5 apresenta a estrutura da GAN proposta neste trabalho.

		Layer	Strides	Filters	Activation
1	Generator	Conv2DTranspose	(1,1)	1	ReLU
2		Conv2DTranspose	(2,2)	128	ReLU
3		Conv2DTranspose	(2,2)	64	ReLU
4		Conv2DTranspose	(1,1)	1	Tanh
5	Discriminator	Conv2D	(1,1)	32	ReLU
6		Conv2D	(2,2)	64	ReLU
7		Conv2D	(2,2)	128	ReLU
8		Dense	-	1	Sigmoid

Tabela 5 – Arquitetura da GAN utilizada nos experimentos deste trabalho.

Após a GAN treinada, é possível gerar fácies somente através de um espaço latente z com amostras gaussianas. Da mesma maneira que o decoder da VAE, aqui utiliza-se a parte geradora. Uma desvantagem é que a GAN não possui uma estrutura similar ao encoder, o que fica difícil a comparação direta entre GAN e VAE. A Figura 26 ilustra o processo de treinamento da GAN com fácies.

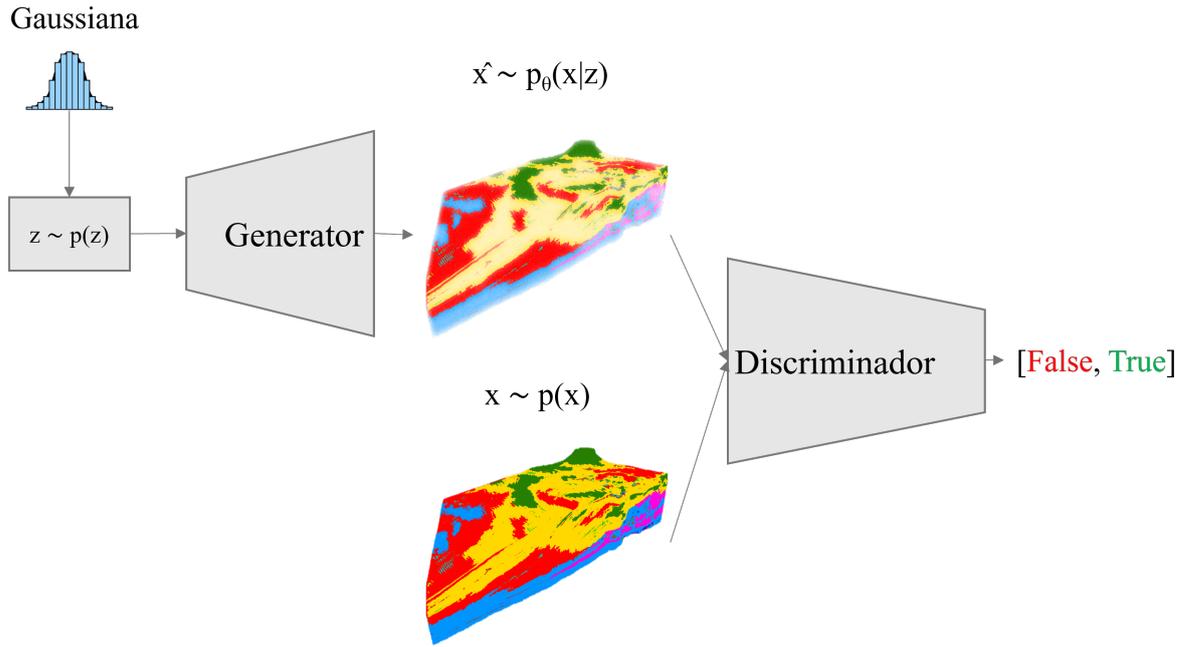


Figura 26 – Treinamento para geração de fácies utilizando GANs.

4.2.3 Proposta para Inversão de Fácies Sísmicas

Através de modelos generativos, VAE e GAN totalmente convolucionais, é possível condicionar a amostragem de fácies com uma distribuição Gaussiana através do espaço latente z . Isto permite que essas redes neurais generativas que sejam integradas com o ES-MDA, já que o método assume que os parâmetros do modelo, neste caso as fácies, sejam representadas por gaussianas. Sendo assim, a formulação original do ES-MDA integrada com redes generativas pode ser reescrita como:

$$z_j^{k+1} = z_j^k + C_{zd}^k (C_{dd}^k + \alpha_k C_e)^{-1} (d_{obs,j}^k - g(m_j^k)) \quad (11)$$

para $j = 1, \dots, N_a$ sendo N_e o tamanho do ensemble, z a representação latente das variáveis do modelo, d_{obs} os dados observados, com $C_e \in \mathbb{R}^{N_a \times N_a}$ sendo a matriz de covariância do erro dos dados, $g(m_j^k)$ é o conjunto de dados simulados. Portanto, as matrizes de covariância $C_{zd} \in \mathbb{R}^{N_z \times N_d}$ e $C_{dd} \in \mathbb{R}^{N_d \times N_d}$ são obtidas durante cada iteração do processo de atualização feita no ES-MDA.

A vantagem da metodologia proposta neste trabalho é a redução dos parâmetros do modelo m , que geralmente possuem a mesma dimensionalidade dos dados observados, para uma dimensão reduzida z , impactando diretamente no tamanho da matriz de cross-covariância C_{md} que precisam ser calculadas a cada iteração do ES-MDA. Além disso, no espaço reduzido é preservado a correlação espacial, tornando compatível a metodologia com técnicas de localização de covariância.

O objetivo é desenvolver, integrar e analisar a capacidade das redes generativas de reparametrizarem e gerarem amostras de fácies a partir do espaço reduzido utili-

zando a aproximação via amostras gaussianas. No caso da VAE, utiliza-se a estrutura decoder e na GAN, a estrutura geradora. A análise do resultado por ser obtido através da comparação entre a diferença dos dados simulados e observados.

A metodologia proposta neste trabalho do ES-MDA com integração da VAE e GAN para inversão de fácies sísmicas consiste em cinco etapas principais, conforme segue:

1. Treinamento da VAE e GAN;
2. Geração das realizações iniciais do conjunto z_j a partir de $\mathcal{N}(0, 1)$;
3. Utilizar a VAE (encoder) ou GAN (geradora) para a reconstrução das fácies m_j a partir de z_j ;
4. Aplicar o *forward model* com as fácies reconstruídas $g(m_j^k)$
5. Calcular o ganho de Kalman \tilde{K} com C_{zd} e C_{dd} reduzidos;
6. Aplique o ES-MDA para atualizar o ensemble latente que representa as fácies z_j ;
7. Repita 3 até 6 de acordo com o número de iterações N_a .

Ao final da execução do ES-MDA, os espaços latentes se tornam atualizados e as fácies geradas com as redes generativas são as variáveis do modelos possíveis para a solução da inversão. A Figura 27 ilustra o processo de inversão de fácies sísmicas com ES-MDA e as redes generativas.

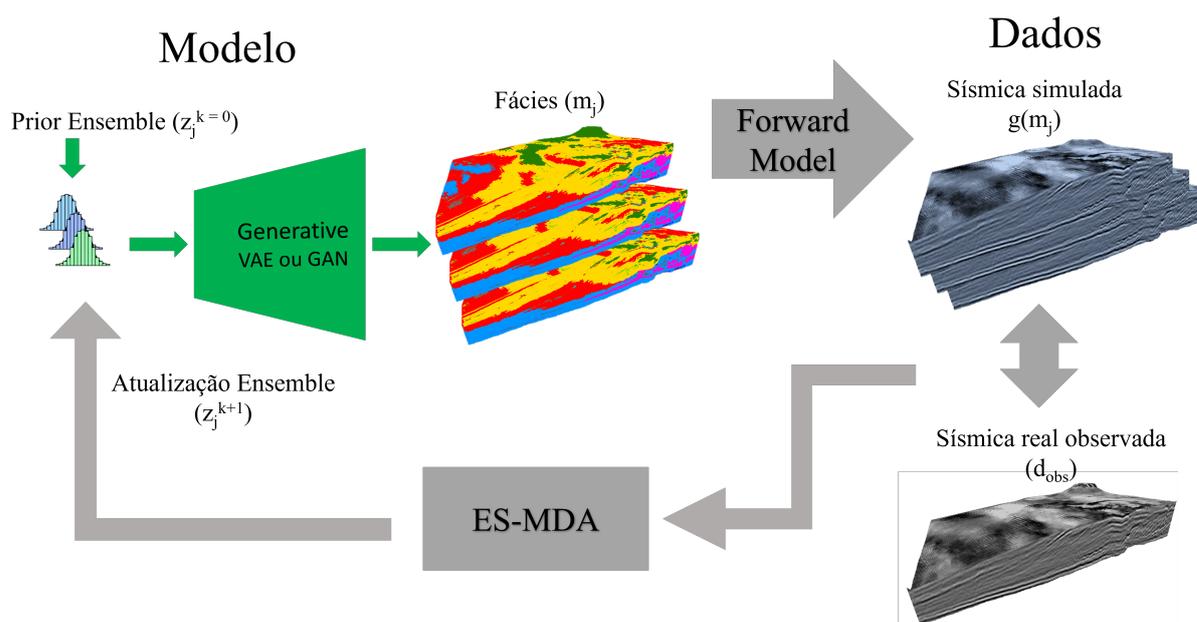


Figura 27 – Proposta deste trabalho para a integração do ES-MDA com redes generativas para inversão de fácies sísmicas.

Dentre as vantagens da metodologia proposta neste trabalho é que permite o uso do ES-MDA para qualquer tipo de problema de inversão, com a execução de *forward model* não lineares e, apesar do Ensemble Smoother não trabalhar diretamente com fácies, a utilização das redes generativas para reparametrizar as fácies para uma informações contínua e gaussiana. A Tabela 6 compara os métodos apresentados e discutidos anteriormente com a proposta deste trabalho.

	Inversão de Fácies	Forward Model Não-linear	ES-MDA	Modelos Generativos
Grana (2018)	✓	* Parcial		
Figueiredo et al. (2019)	✓			
Liu e Grana (2018)		✓	✓	
Canchumuni et al. (2021)	✓	✓	✓	* Rede Neural com camadas totalmente conectadas
Este trabalho	✓	✓	✓	✓

Tabela 6 – Comparação dos trabalhos relacionados com a proposta deste trabalho para inversão de fácies sísmicas.

5 EXPERIMENTOS E RESULTADOS

Neste capítulo, o objetivo é apresentar os experimentos e resultados realizados no problema de assimilação da sísmica 4D em ajuste de histórico e a reparametrização das fácies para a inversão de fácies sísmicas. Primeiro será abordado o treinamento das redes neurais profundas propostas nas metodologias deste trabalho, apresentando o conjunto de dados utilizado e a etapa de treinamento correspondente, iniciando com os Autoencoders 2D e 3D e posteriormente as redes generativas VAE e GAN. Após são apresentados os experimentos para cada problema de inversão, ajuste de histórico e inversão de fácies sísmicas, utilizando cada abordagem correspondente juntamente com o estudo de casos utilizada para cada um. Ao final, é apresentada uma discussão sobre os experimentos realizados e os resultados obtidos.

5.1 AJUSTE DE HISTÓRICO E SÍSMICA 4D

A assimilação da sísmica 4D no processo de ajuste de histórico é um desafio devido à grande quantidade de dados da sísmica e a redundância da mesma. Neste caso, ao assimilar a sísmica 4D, dois problemas principais podem ocorrer utilizando o ES-MDA, sendo a demanda de poder computacional elevada devido às matrizes de auto-covariância dos dados observados ficarem muito grandes e o colapso do ensemble para uma solução não ótimo com pouca variabilidade entre as realizações.

A proposta deste trabalho envolve o treinamento e aplicação de Autoencoders 2D e 3D com imagens naturais e volumes encontrados na literatura para depois realizar o ajuste fino, *transfer learning*, somente das camadas latentes utilizando a sísmica 4D do reservatório. Com isso, o experimento se baseia em utilizar a parte do encoder para extrair as características das sísmicas 4D observadas e simuladas, fazendo-as reduzir à um espaço latente com uma menor quantidade de dados, sendo que estas características serão utilizadas no ES-MDA para a atualização dos modelos do reservatório.

5.1.1 Treinamento dos Autoencoders

A primeira etapa dos experimentos é o treinamento dos Autoencoders para serem posteriormente integradas com o ES-MDA. Cada rede foi treinada com um conjunto de dados encontrados na literatura de acordo com a estrutura e o tipo de entrada, 2D ou 3D, e a aplicação da rede.

5.1.1.1 Coco Dataset 2D

O COCO (Common Objects in Context) dataset (LIN *et al.*, 2014) de 2017 é um conjunto de imagens amplamente utilizado na área de visão computacional. Ele

foi desenvolvido para promover a pesquisa em algoritmos de detecção de objetos, segmentação, extração de características, entre outras tarefas. Este conjunto de dados possui grande diversidade e complexidade, contendo imagens de alta resolução com uma vasta variedade de objetos e cenários.

O COCO 2017 é a versão mais recente que contém mais de 200.000 imagens, das quais aproximadamente 118.000 são imagens de treinamento, 5.000 são imagens de validação, e 41.000 são imagens de teste. As imagens foram coletadas de cenas cotidianas que refletem uma grande variedade de contextos, garantindo que os algoritmos treinados com este conjunto de dados possam generalizar bem para situações do mundo real, como ilustrado na Figura 28.



Figura 28 – Exemplo de imagens do conjunto de dados COCO 2017.

5.1.1.2 Treinamento do Autoencoder 2D

A rede Autoencoder 2D proposta neste trabalho é baseada na estrutura da VGG-19, sendo que a estrutura encoder já possui os pesos pré-treinados. Portanto, é somente necessário treinar a estrutura decoder que irá reconstruir a imagem de entrada a partir de um espaço latente reduzido.

Os hiperparâmetros utilizados foram escolhidos de forma experimental, com o total de 200 épocas, com função de erro sendo composta pelo conjunto erro quadrático médio (MSE), erro médio absoluto (MAE). Como função de otimização foi utilizada a Adam (KINGMA; BA, 2014). Com 4 GPUs V100, o tempo de treinamento foi de 21,4 horas. O erro obtido foi de 912,08. A Figura 29 ilustra algumas imagens reconstruídas pelo Autoencoder 2D proposto neste trabalho.

Após o treinamento, o objetivo é poder utilizar a camada mais profunda para extrair as características de uma sísmica 4D, que apesar de geralmente possuírem dimensão tridimensional, a profundidade por ser separada camada por camada e utilizada com entrada do Autoencoder 2D. Por exemplo, um volume de tamanho tridimensional $100 \times 100 \times 50$ terá 50 imagens de camadas extraídas para o Autoencoder 2D e a redução será para cada uma das 50 imagens, características latentes de tamanho 25×25 . Com isso, assume-se que imagens semelhantes tendem a ter características similares. Além disso, a técnica de transfer-learning pode ser aplicada para fazer um ajuste fino

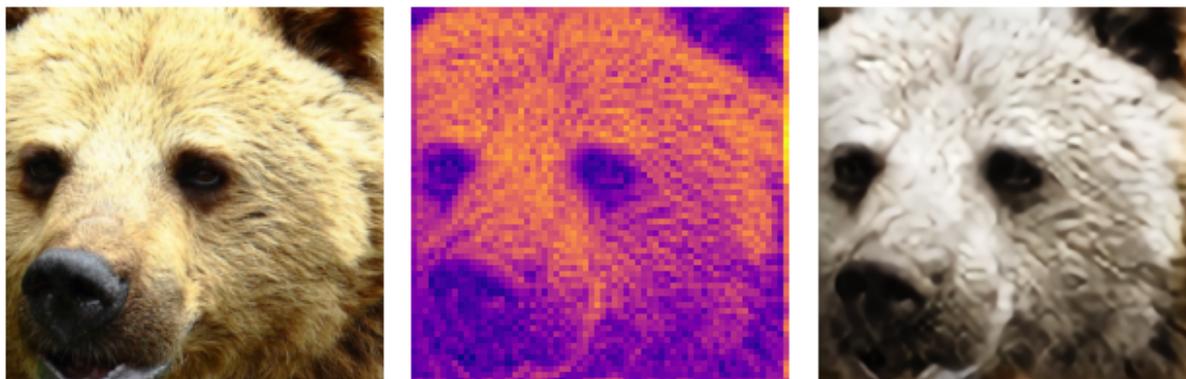


Figura 29 – Autoencoder 2D proposta neste trabalho no processo de reconstrução de imagens com a entrada (esquerda), latente (centro) e saída reconstruída (direita).

no pesos para que o Autoencoder possa aumentar sua performance em imagens que representem as camadas da sísmica 4D.

5.1.1.3 MNIST Dataset 3D

O MNIST 3D (DENG, 2012) é uma adaptação tridimensional do famoso conjunto de dados MNIST, que é amplamente utilizado para o treinamento e avaliação de modelos de aprendizado de máquina, especialmente em tarefas de reconhecimento de dígitos manuscritos. Enquanto o MNIST original contém imagens bidimensionais de 28×28 pixels de dígitos manuscritos, o MNIST 3D estende essa ideia para o domínio tridimensional, fornecendo 10.000 volumes de dados de treinamento de 2.000 para validação, com tamanho $28 \times 28 \times 28$. Cada volume 3D é associado a um rótulo que indica o dígito representado, similar ao conjunto original, como exemplificado na Figura 30.

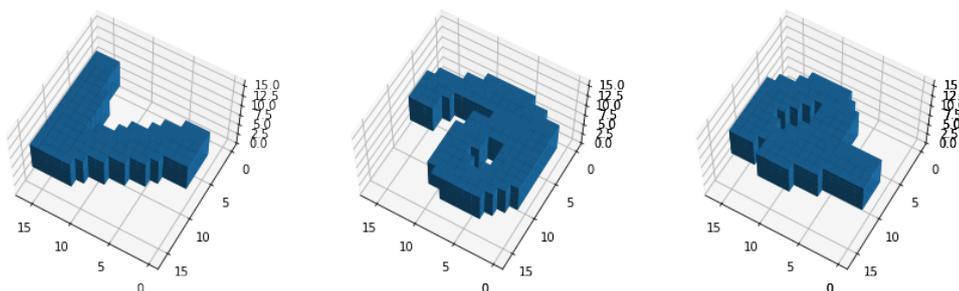


Figura 30 – Exemplo de volumes do conjunto de dados MNIST 3D.

Neste trabalho, o MNIST 3D é utilizado para treinar o Autoencoder 3D e as características aprendidas a partir de conjunto de dados, possa servir para adaptar a rede neural para a extração de características da Sísmica 4D.

5.1.1.4 Treinamento do Autoencoder 3D

Neste trabalho, a diferença do Autoencoder 3D proposto de um Autoencoder 3D tradicional é a redução de somente duas dimensões do volume de entrada, sendo a largura e altura (x,y), preservando sua profundidade. Neste caso, por exemplo, um volume de tamanho tridimensional $100 \times 100 \times 100$ terá uma redução somente nas duas primeiras dimensões, resultando em um volume latente de $25 \times 25 \times 100$. Esta decisão se dá pelo fato de ser possível aplicar técnicas de localização do ES-MDA diretamente na informações latente, pois caso fosse reduzida a terceira dimensão de profundidade, seria necessário estudar outras alternativas de localização.

Da mesma maneira, o Autoencoder 3D foi treinado durante 200 épocas, com função de erro sendo composto pelo conjunto erro quadrático médio (MSE), erro médio absoluto (MAE) e otimizador Adam. O processo de treinamento levou em torno de 3,85 horas, com o erro MSE+MAE em 79,5.

5.1.2 ES-MDA com Autoencoders para Ajuste de Histórico

Após o treinamento dos Autoencoders 2D e 3D, as redes foram integradas com o ES-MDA para o processo de ajuste de histórico com a assimilação da sísmicas 4D. Para estes experimentos, foi utilizado um reservatório sintético Punq-S3 para avaliar a performance da metodologia proposta neste trabalho e outro denominado Fake 3D com maior dimensionalidade para comparar o tempo de processamento.

5.1.2.1 Punq-S3 Benchmark

O PUNQ-S3 (Production Optimization of the Nameless-Queensland) é um modelo de reservatório 3D baseado em dados reais do Mar do Norte desenvolvido por um grupo de empresas de petróleo, institutos de pesquisa e universidades. É amplamente utilizado em projetos de geociências, especialmente na área de engenharia de reservatórios de petróleo para comparar métodos para quantificar a avaliação de incerteza no ajuste de histórico (FLORIS *et al.*, 2001).

O modelo do PUNQ-S3 inclui informações detalhadas sobre a porosidade, permeabilidade e saturação de fluidos do reservatório. O benchmark define vários cenários de produção que permitem testar diferentes estratégias de desenvolvimento do campo. Estes cenários incluem variações nas localizações dos poços, taxas de produção, e injeção de água ou gás. A Figura 31 ilustra o modelo reservatório Punq-S3.

A partir das propriedades de porosidade e permeabilidade, pode-se estimar as sísmica 4D durante a simulação do ciclo produtivo do reservatório. Neste caso, a sísmica 4D utilizada foi a diferença da impedância, propriedade elástica, obtida a partir das propriedades petrofísicas (porosidade e permeabilidade) através da execução do *forward model*. Os resultados dos métodos testados no PUNQ são avaliados com base

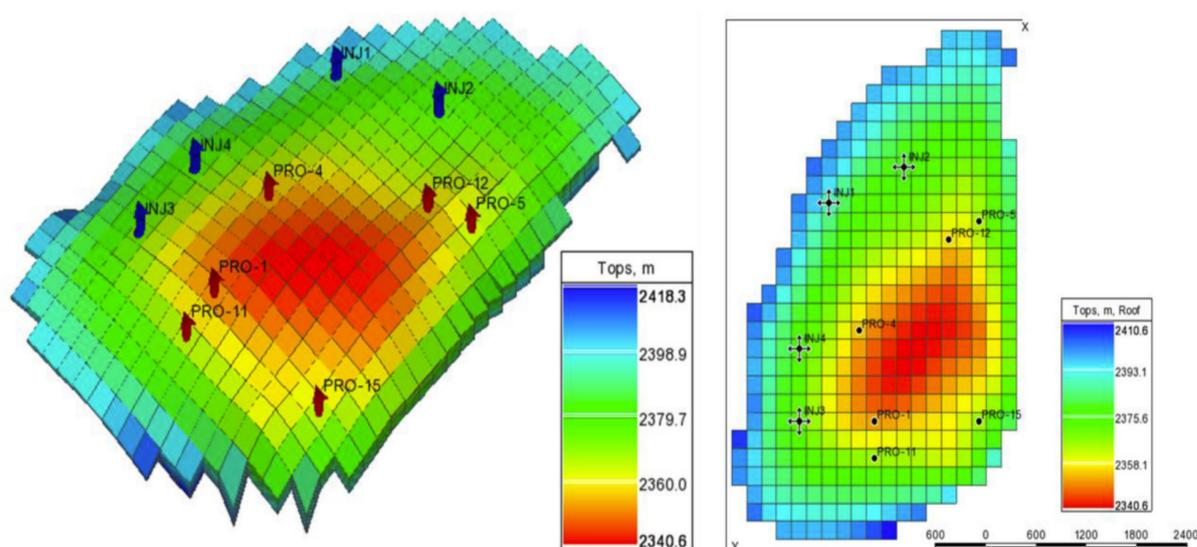


Figura 31 – Modelo de reservatório PUNQ-S3 (FLORIS *et al.*, 2001).

na função objetiva, Equação 4, entre a sísmica 4D simulada e a sísmica real observada presente nos dados do PUNQ-S3.

O PUNQ-S3 original é um modelo de 5 camadas dimensionado por blocos de grade $19 \times 28 \times 5$ com apenas 1,761 ativos. Cada bloco tem 180 m nas direções x e y . Neste trabalho, é utilizado uma versão do PUNQ refinada com uma grade mais fina de tamanho $57 \times 84 \times 15$ para simular um reservatório de maior dimensão.

5.1.2.2 Processamento e Assimilação das Sísmica 4D

Nesta etapa de ajuste de histórico com a assimilação da sísmica 4D foram realizados três experimentos principais: aplicação do ES-MDA tradicional, ES-MDA com Autoencoder 2D e ES-MDA com Autoencoder 3D. Os experimentos têm como objetivo testar a metodologia proposta neste trabalho, que é a utilização de Autoencoders Convolucionais 2D e 3D para a extração de características das sísmicas 4D simuladas e observadas, afim de reduzir a quantidade de informação a serem assimiladas pelo ES-MDA, cujo resultado será a otimização em termos de tempo de execução e variabilidade no ensemble. Em relação ao hardware, todos os experimentos foram realizados no mesmo dispositivo com processador i7-9700K CPU com 8 núcleos e uma GPU NVIDIA RTX 3090 com 10,496 núcleos executando CUDA 10.1.

No processo de assimilação, foram utilizados as propriedades de porosidade, permeabilidade I e permeabilidade J do PUNQ-S3 como parâmetros do modelo no ajuste de histórico. Os dados simulados que representam a sísmica 4D constituem na impedância obtida a partir dessas propriedades através do modelo direto, *forward model*.

O primeiro experimento é a execução do ES-MDA tradicional para atualizar os modelos de porosidade e permeabilidade do PUNQ-S3 para a assimilação da sísmica

4D e analisar a função objetivo em conjunto com o tempo de execução. Como mencionado anteriormente, a assimilação começa com um conjunto de N_e realizações, representando as possibilidades *a priori* dos parâmetros do modelo $m^{k=0}$. Neste caso, usamos um conjunto de $N_e = 200$ e o número de assimilações $N_a = 4$. Em seguida, a equação ES-MDA 2 é usada para atualizar m^{k+1} com base no ganho de Kalman K calculado utilizando a Equação (3) obtida das matrizes de covariância partir de C_{md} e C_{dd} . Após satisfazer N_a , as sísmicas simuladas dos modelos atualizados são avaliadas usando a função objetiva da Equação (4). O tempo total de consumo do ES-MDA padrão é de 26,8 minutos. Ao final, entre o conjunto de valores da função objetiva obtida a partir da comparação entre os dados simulados e o dado observado, são calculados o desvio padrão $\sigma = 0,00161$ e a média de $\mu = 0,6268$.

O segundo experimento visa integrar o Autoencoder 2D pré-treinado com COCO 2017 para extrair características dos dados sísmicos 4D. Na rede autoencoder 2D, a profundidade de cada camada do reservatório PUNQ é usada como entrada, resultando em 15 imagens. A extração de características é processada separadamente para cada imagem, assumindo que uma imagem semelhante pode resultar em características semelhantes. O resultado da reconstrução sísmica com o modelo profundo 2D foi aceitável, com $MSE + MAE = 166,74$. Seguindo a metodologia proposta, aplicamos ajuste fino nas camadas latentes para melhorar a reconstrução das imagens. Usando as amostras de dados sísmicos do PUNQ, ajustamos o modelo 2D por 3,2 minutos durante 20 épocas, reduzindo o erro para 73,28. Como resultado, alguns detalhes da sísmica do PUNQ são melhor reconstruídos na saída, como mostrado na Figura 32).

Além disso, podemos observar os efeitos na alteração das características do espaço latente do Autoencoder 2D na imagem de saída da rede. Pode-se observar que a alteração em somente um ponto do espaço latente resultou em alterações somente em determinada região da imagem de saída, sendo assim, possível a aplicação de técnicas de localização do ES-MDA diretamente nas características extraídas, pois a correlação espacial é preservada no espaço reduzido. A Figura 33 mostra os efeitos na imagem de saída alterando somente um ponto das características extraídas via a estrutura totalmente convolucional do Autoencoder 2D.

Baseado no mesmo conjunto com $N_e = 200$ realizações anteriores usado no ES-MDA padrão, aplicamos o encoder do Autoencoder 2D ajustado nos dados observáveis d e na sísmica simulada $g(m^k)$. Usando as características z extraídas de d e $g(m^k)$, as matrizes de cross-covariância C_{mz} têm um tamanho de $200 \times 4,410$ elementos. O tempo para atualizar as realizações do modelo foi de 4,1 minutos para cada iteração do ES-MDA, resultando em um tempo total de aproximadamente 16,4 minutos com $N_a = 4$. Isso representa uma redução de 38% no tempo de processamento em comparação com o ES-MDA padrão.

Os resultados da função objetivo com desvio padrão $\sigma = 0,00438$ indicam um aumento de 2,72 vezes na variabilidade do conjunto em comparação com o ES-MDA

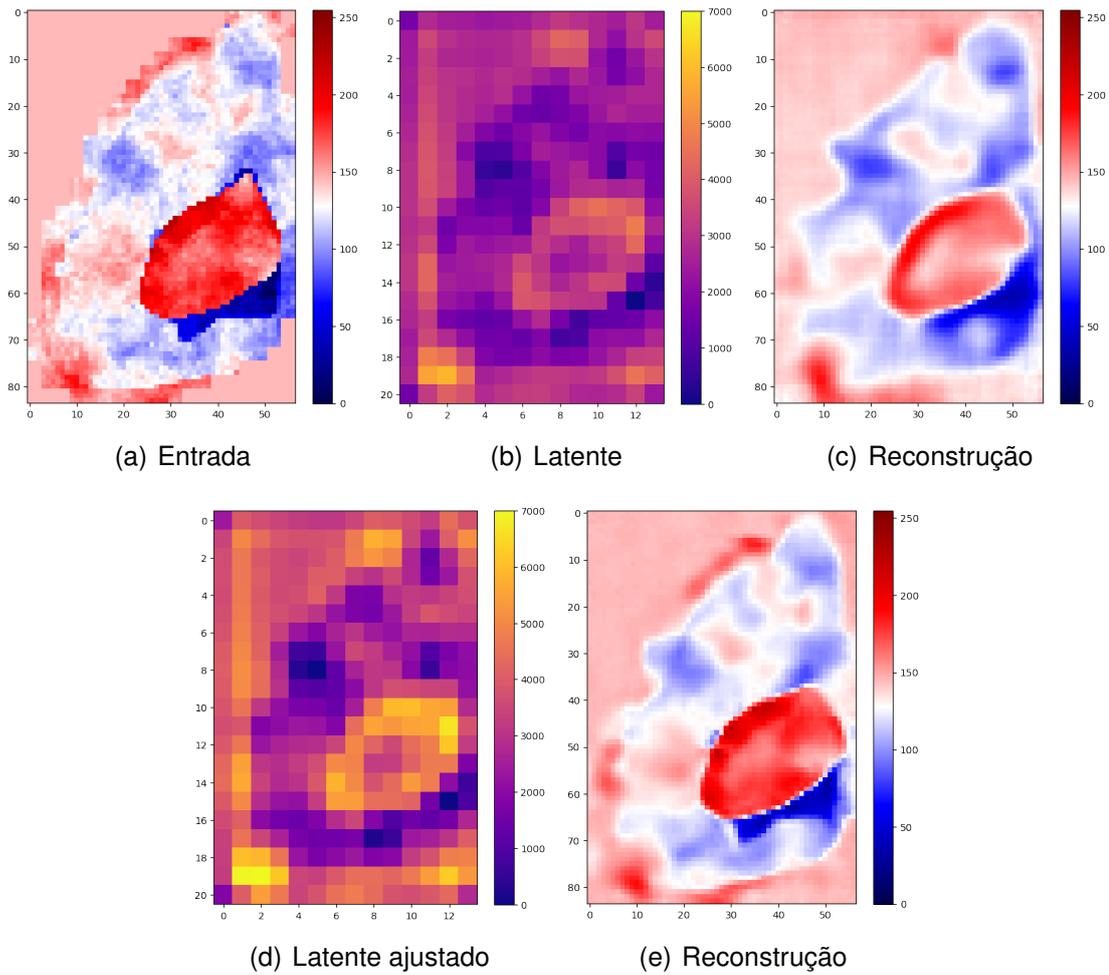


Figura 32 – Resultados para a reconstrução da sísmica 4D com ajuste fino do Autoencoder.

padrão. Com uma média de $\mu = 0,7238$, observamos que a redução das sísmicas 4D com Autoencoder causou um erro maior ao comparar a sísmica simulada com os dados observados. Esse efeito é esperado devido à redução e perda de informações apresentadas no Autoencoder 2D durante o processo de treinamento (GRANA; AZEVEDO *et al.*, 2022). Para comparação, os histogramas da função objetivo para o caso ES-MDA padrão e o caso FCA 2D são mostrados na Figura 36.

O terceiro experimento com PUNQ-S3 é a integração do autoencoder 3D. Usando as mesmas $N_e = 200$ realizações, cada volume 3D é usado como entrada ao invés das imagens de camadas 2D separadas. Seguindo a etapa de aprendizado por transferência, reduzimos o erro de reconstrução do Autoencoder 3D de 419,05 para 43,50. Na integração do ES-MDA, a extração de características é mais rápida do que no modelo 2D, pois é feita para todo o volume de uma vez. Cada iteração do ES-MDA foi executada em 3,4 minutos, totalizando 13,6 minutos. Isso representa uma redução de 17% em comparação com a integração do Autoencoder 2D e 50% em relação ao ES-MDA padrão. A função objetivo indica um aumento menor na variabilidade do conjunto em comparação com o FCA 2D, com $\sigma = 0,00324$ e $\mu = 0,6722$ (Figura 35).

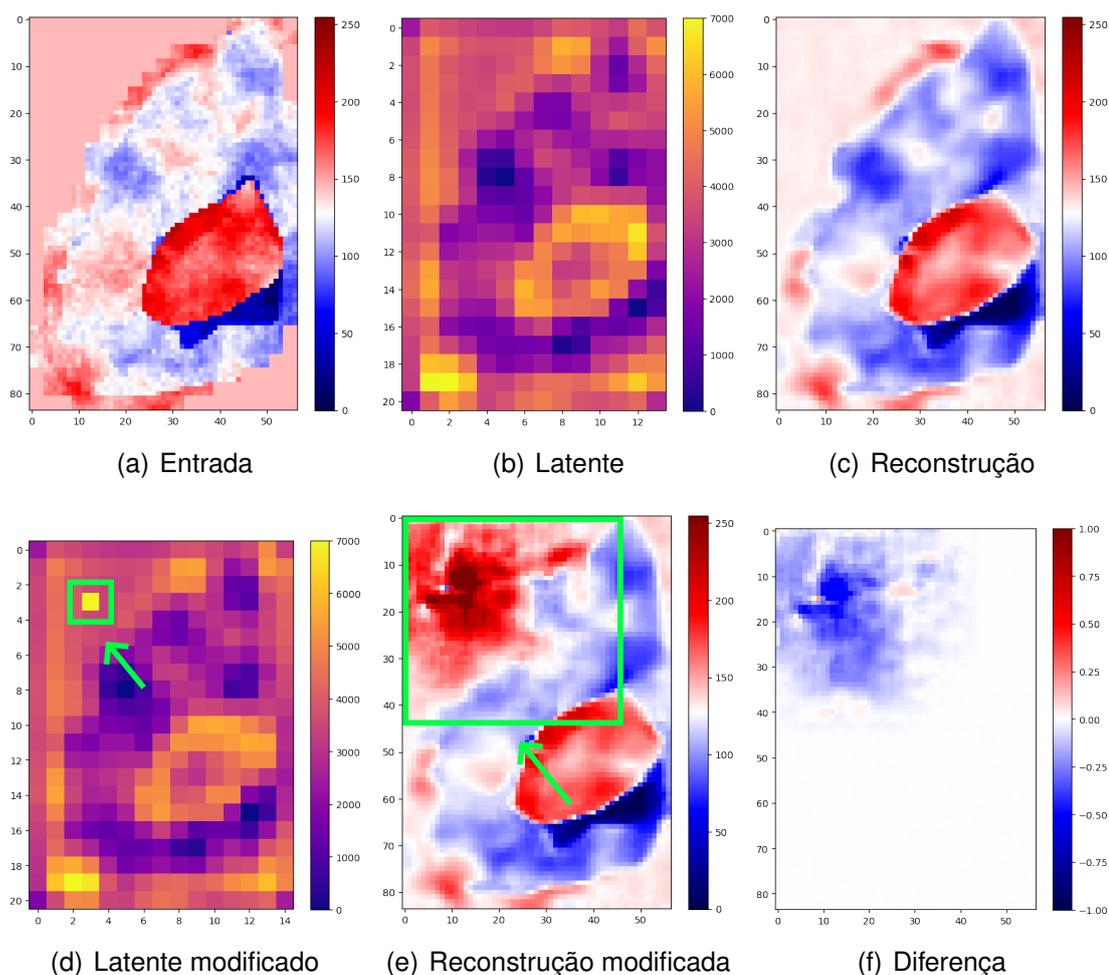


Figura 33 – Resultados na alteração de um ponto do espaço latente para as características extraídas através do Autoencoder totalmente convolucional.

Neste caso de teste, também foi comparado visualmente os resultados para as sísmicas 4D obtidas entre a prior e posterior, após o processo de atualização de todos os três experimentos: ESM-MDA, ES-MDA-2D (com Autoencoder 2D) e ES-MDA-3D (com Autoencoder 3D). Usando a sísmica real do PUNQ-S3 como referência, a assimilação de dados utilizando o Autoencoder 2D e o 3D mostraram resultados promissores em comparação com o ES-MDA padrão. A sísmica simulada utilizando o encoder do Autoencoder 3D parece superior em comparação com o Autoencoder 2D, como mostrado na Figura 34.

De acordo com a função objetiva, comparando os resultados entre o Autoencoder 2D e 3D, podemos observar que o Autoencoder 3D teve uma performance superior em relação ao Autoencoder 2D, devido ao erro ser menor entre as sísmicas simuladas e observadas. Também destaca-se a vantagem de que, apesar do Autoencoder 3D demandar maior tempo de treinamento, o tempo de inferência é mais baixo, pois a rede recebe todo o volume de sísmica, ao invés de fazer a extração camada por camada como acontece no Autoencoder 2D.

Ao longo do processo de assimilação, podemos observar que o erro entre as

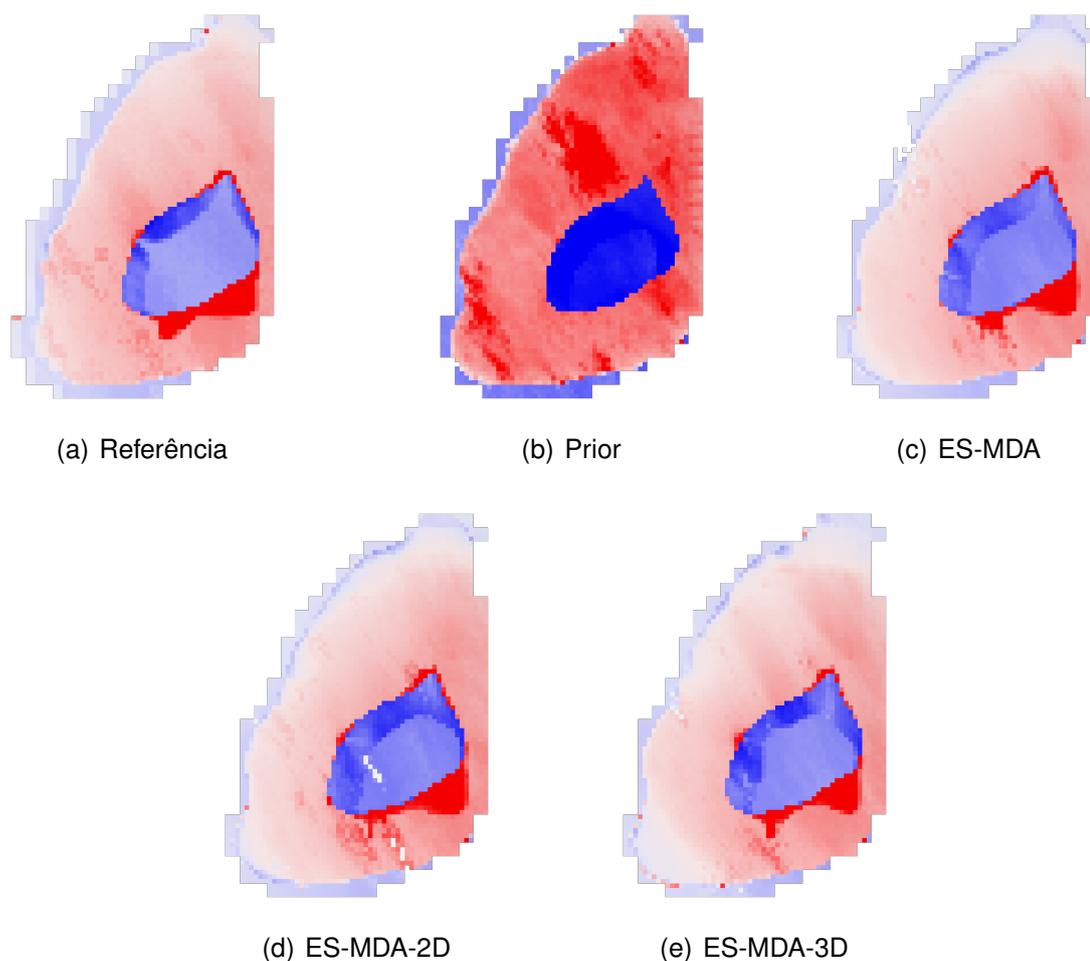


Figura 34 – Resultados comparando a referência e utilizando ES-MDA, ES-MDA com Autoencoder 2D e Autoencoder 3D.

sísmicas simuladas e observada cai ao longo do processo. Além disso, podemos observar que o erro em relação ao espaço latente também segue a mesma tendência, mostrando que sísmicas similares tendem a ter características extraídas pelo Autoencoder também similares. A Figura 35 ilustra a função objetiva computada para cada experimento e a Figura 36 os histogramas da função objetiva computada para cada modelo do ensemble utilizada em cada experimento.

5.1.2.3 Caso Fake 3D

Para testar a metodologia em um caso de reservatório maior, foi criado um caso denominado Fake 3D de tamanho de grade $150 \times 150 \times 50$ células. O principal objetivo é comparar o desempenho computacional entre o ES-MDA padrão e o ES-MDA com Autoencoder para a redução de dados de sísmica 4D em grandes reservatórios.

No caso anterior, o desempenho do ES-MDA com autoencoders totalmente convolucionais melhorou em aproximadamente 38% no tempo de processamento para pequenos reservatórios. Portanto, utilizando o reservatório "Fake" com um tamanho

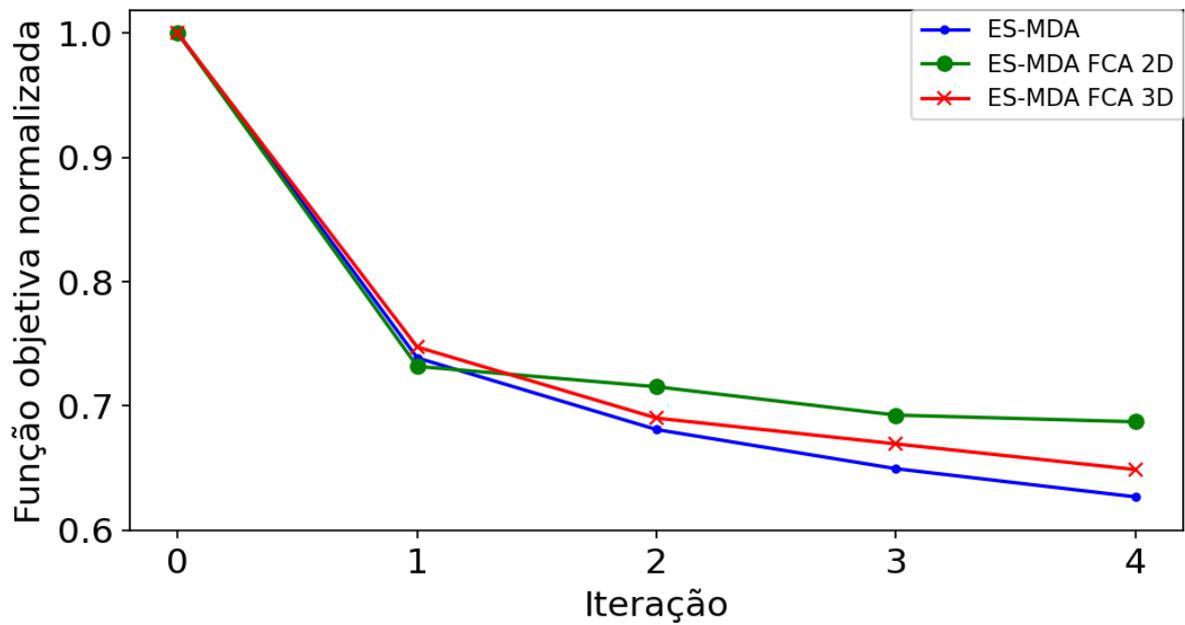


Figura 35 – Função objetiva computada durante o processo de assimilação com ES-MDA e ES-MDA integrado com Autoencoder 2D e 3D.

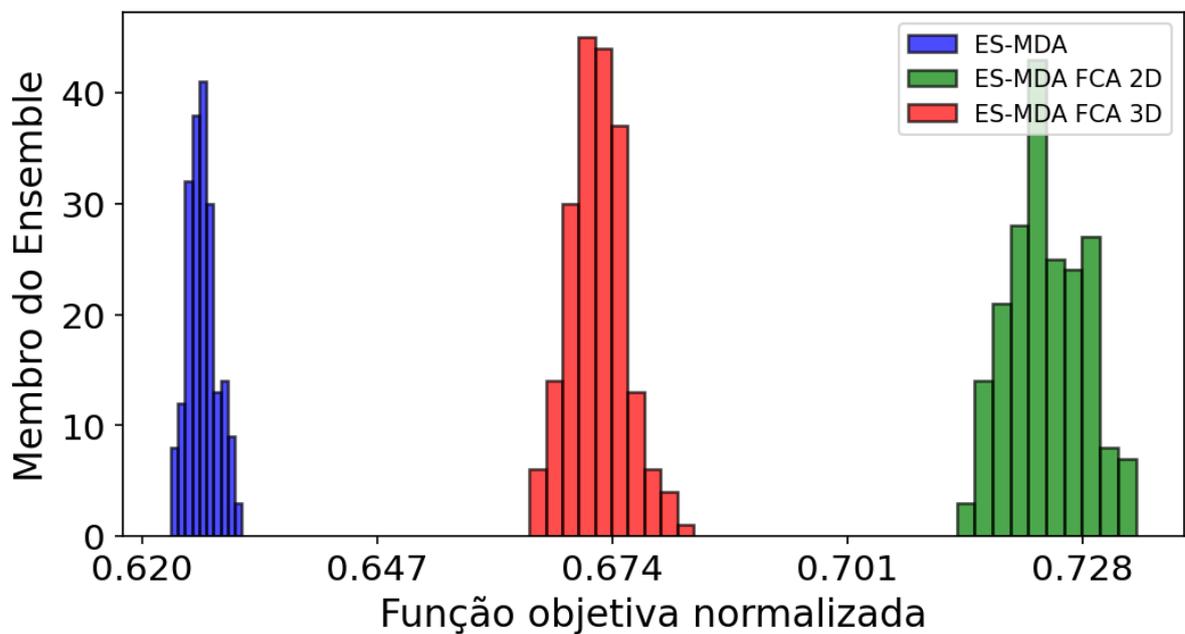


Figura 36 – Histograma do valor da função objetiva computada para cada membro do ensemble durante o processo de assimilação com ES-MDA e ES-MDA integrado com Autoencoder 2D e 3D.

de $150 \times 150 \times 50$ células, foi aplicado apenas o Autoencoder 3D, devido a sua performance superior se comparado ao Autoencoder 2D. O processo de *transfer-learning* foi feito com dados de sísmica 4D do Fake durante 20 épocas com um tempo total de 24 minutos, reduzindo o erro de reconstrução para 32.3.

Devido a maior dimensionalidade do reservatório, os parâmetros do ES-MDA foram definidos com tamanho de ensemble $N_e = 200$ realizações e $N_a = 2$ iterações. A quantidade de iterações foi mais baixa devido a aplicação do ES-MDA tradicional, que

exigiu muito mais tempo de processamento e memória para armazenar as matrizes de covariância. Portanto, após aplicar o ES-MDA tradicional, o próximo teste foi executado o ES-MDA com o Autoencoder 3D. Ao final, a função objetivo mostra uma melhor minimização do erro em relação a sísmica 4D observada e simulada utilizando o ES-MDA com Autoencoder 3D do que com o ES-MDA tradicional, como ilustrado na Figura 37.

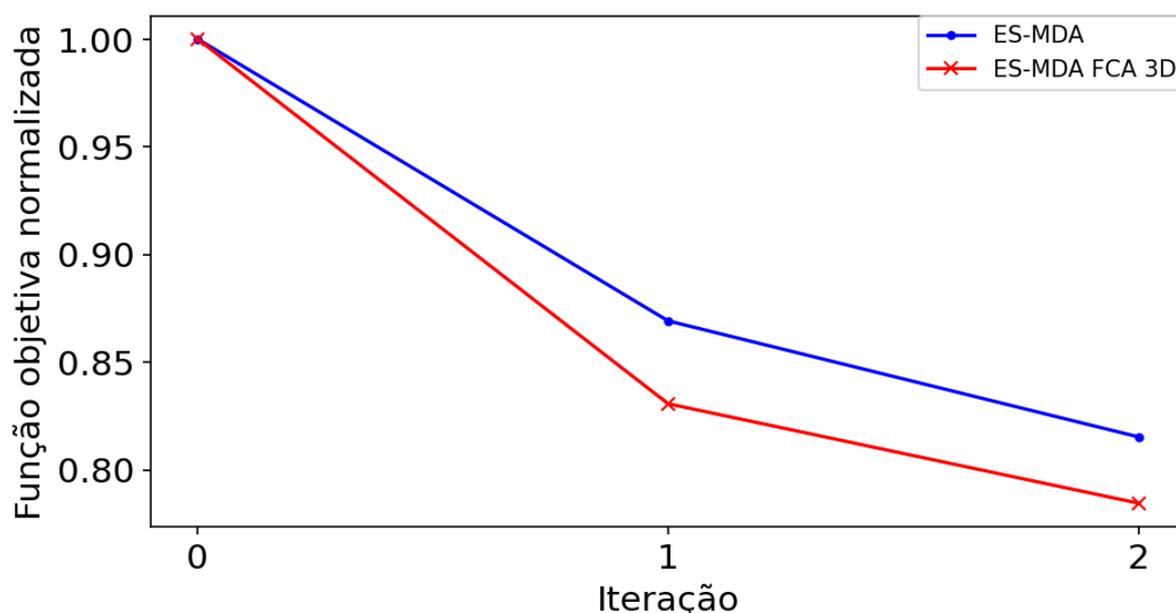


Figura 37 – Resultado para o caso Fake 3D com ES-MDA e ES-MDA integrado com Autoencoder 3D.

Em relação ao tempo de processamento, o processo de atualização do ES-MDA tradicional executou em 64,5 horas e o ES-MDA com Autoencoder 3D em 4,5 horas. Isso representa uma melhoria de 90% no tempo de processamento. Portanto, quanto maior a dimensionalidade do reservatório, mais significativa será a redução do tempo de atualização dos modelos de reservatórios com ES-MDA e Autoencoders, presentes na metodologia proposta neste trabalho

5.2 INVERSÃO DE FÁCIES SÍSMICAS

O processo de inversão de fácies sísmicas é composto do processamento de informações de diferentes domínios, tanto do discreto (fácies) como do contínuo (sísmica). Neste caso, o objetivo deste experimento é utilizar redes do tipo generativas treinadas para reparametrizar as fácies discretas para um espaço regular gaussiano contínuo afim de poderem ser processadas pelo ES-MDA.

5.2.1 Treinamento das Redes Generativas

Neste seção será apresentada o conjunto de dados de fácies e os parâmetros utilizados para o treinamento das redes generativas Variational Autoencoder e Generative

Adversarial Net. O objetivo é que estas redes generativas treinadas sejam integradas com o ES-MDA para a reparametrização das fácies que são discreta para contínuas e adaptá-las para o problema de inversão de fácies sísmicas.

5.2.1.1 Facies Dataset 2D

No trabalho de [Figueiredo, Rodrigues *et al.* \(2019\)](#), os autores utilizaram dados do reservatório pré-sal do campo de Lula/Tupi, localizado na Bacia de Santos, Brasil, onde com base no registro dos poços e nos relatórios gerados a partir da base de dados da Agência Nacional do Petróleo (ANP), foram identificadas quatro tipos de fácies: halita, anidrita (ADT), carbonato de alta porosidade (HPC) e carbonato de baixa porosidade (LPC). [Figueiredo, Rodrigues *et al.* \(2019\)](#) também definiram duas matrizes de transição para o modelo *a priori*, a matriz de transição vertical P_v e a matriz de transição horizontal P_h . O modelo assume que a camada de halita é presente na parte do topo do reservatório, sendo que a camada de anidrita só pode estar presente entre a halita e o carbonato, e por fim as fácies carbonáticas assumem um nível alto de heterogeneidade nas direções laterais. A Figura 38 ilustra as matrizes de transição utilizadas no trabalho de [Figueiredo, Rodrigues *et al.* \(2019\)](#).

		To:			
		LPC	HPC	ADT	Halite
$P_v =$	From: LPC	0.6	0.4	0	0
	HPC	0.6	0.4	0	0
	ADT	0.33	0.33	0.34	0
	Halite	0.125	0.125	0.25	0.5

		To:			
		LPC	HPC	ADT	Halite
$P_h =$	From: LPC	0.4	0.4	0.1	0.1
	HPC	0.4	0.4	0.1	0.1
	ADT	0.1	0.1	0.6	0.2
	Halite	0.1	0.1	0.2	0.6

Figura 38 – Matrizes de transição utilizadas para gerar amostras de fácies de um reservatório carbonático do pré-sal. Adaptada de [Figueiredo, Rodrigues *et al.* \(2019\)](#)

A partir das matrizes de transição propostas no trabalho de [Figueiredo, Rodrigues *et al.* \(2019\)](#), foram geradas amostras de traços utilizando cadeias de Markov. Para o conjunto de treinamento, foram gerados 50.000 imagens de fácies a partir de P_v e P_h , com tamanho de 48×48 *pixels*, onde é possível observar que a halita permanece predominantemente ao topo da amostras de fácies gerada. A Figura 39 mostra alguns exemplos gerados com Markov para o conjunto de dados de treinamento.

5.2.1.2 Variational Autoencoder 2D

Neste trabalho foram testadas duas arquiteturas diferentes de Variational Autoencoder, uma com camadas totalmente conectadas no espaço latente (VAE) e outra que é proposta deste trabalho, que é formada por uma arquitetura totalmente convolucional (FCVAE).

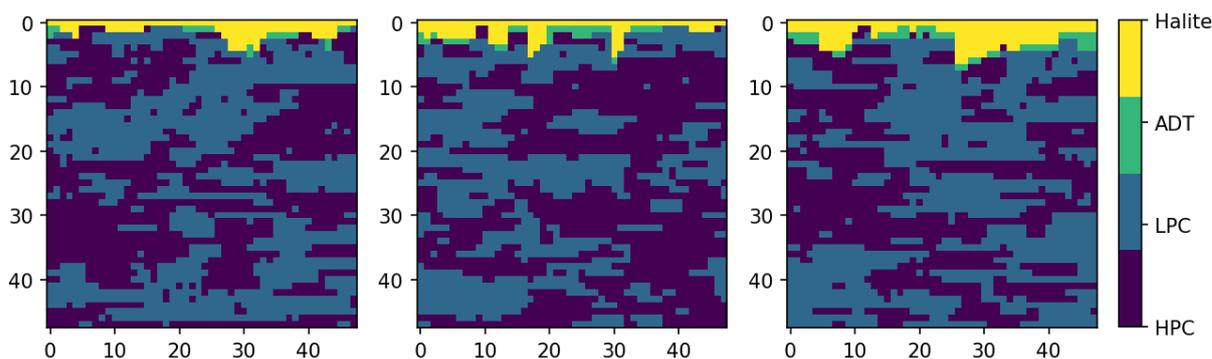


Figura 39 – Exemplos de amostras de fácies geradas a partir da cadeia de Markov utilizando P_v e P_h .

Após o desenvolvimento do conjunto de dados de treinamento de fácies, os hiperparâmetros de treinamento foram definidos de forma experimental com o acompanhamento da minimização do erro de reconstrução da imagem de fácies, com ambas as VAEs foram treinadas durante 100 épocas, utilizando a função de otimização Adam, com um *learning rate* de 0.001. Durante o treinamento, a VAE com camadas totalmente conectadas teve uma queda menor na função de erro do que a VAE totalmente convolucional. Este efeito pode ser observado na Figura 40, onde ilustra a queda da função de erro para ambas as redes durante o treinamento.

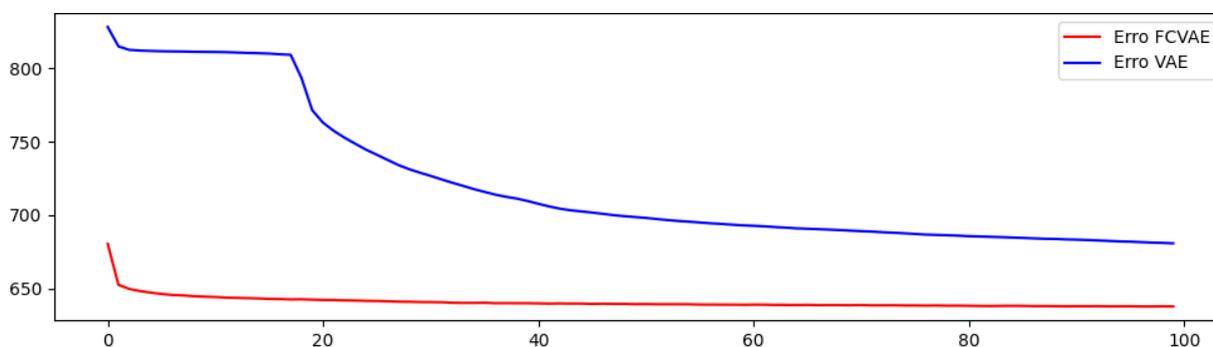


Figura 40 – Função de erro durante o treinamento da VAE e VAE totalmente convolucional proposta neste trabalho.

As camadas convolucionais são úteis para adquirir características dos dados que são espacialmente correlacionadas. Podemos observar que durante o treinamento, apesar das primeiras épocas os modelos não gerarem realizações de fácies consistentes com a matriz de transição, ao longo do treinamento a rede aprende que a camada de Halita fica ao topo do reservatório, sendo seguida muitas vezes por uma fina camada de Anidrita e por fim, no restante do reservatório as fácies carbonatos de alta e baixa porosidade se intercalam.

Após as VAEs treinadas, o objetivo é verificar se ambas conseguem gerar imagens de fácies semelhantes ao de conjunto de treinamento, onde deve-se respeitar a sequência das fácies na abordagem topo para a base, com a Halita no topo da imagem, seguindo por uma possível Anidrita e então contendo os carbonatos de alta e

baixa porosidade. A Figura 41 apresenta as imagens de fácies geradas por ambos os modelos, VAE e VAE totalmente convolucional.

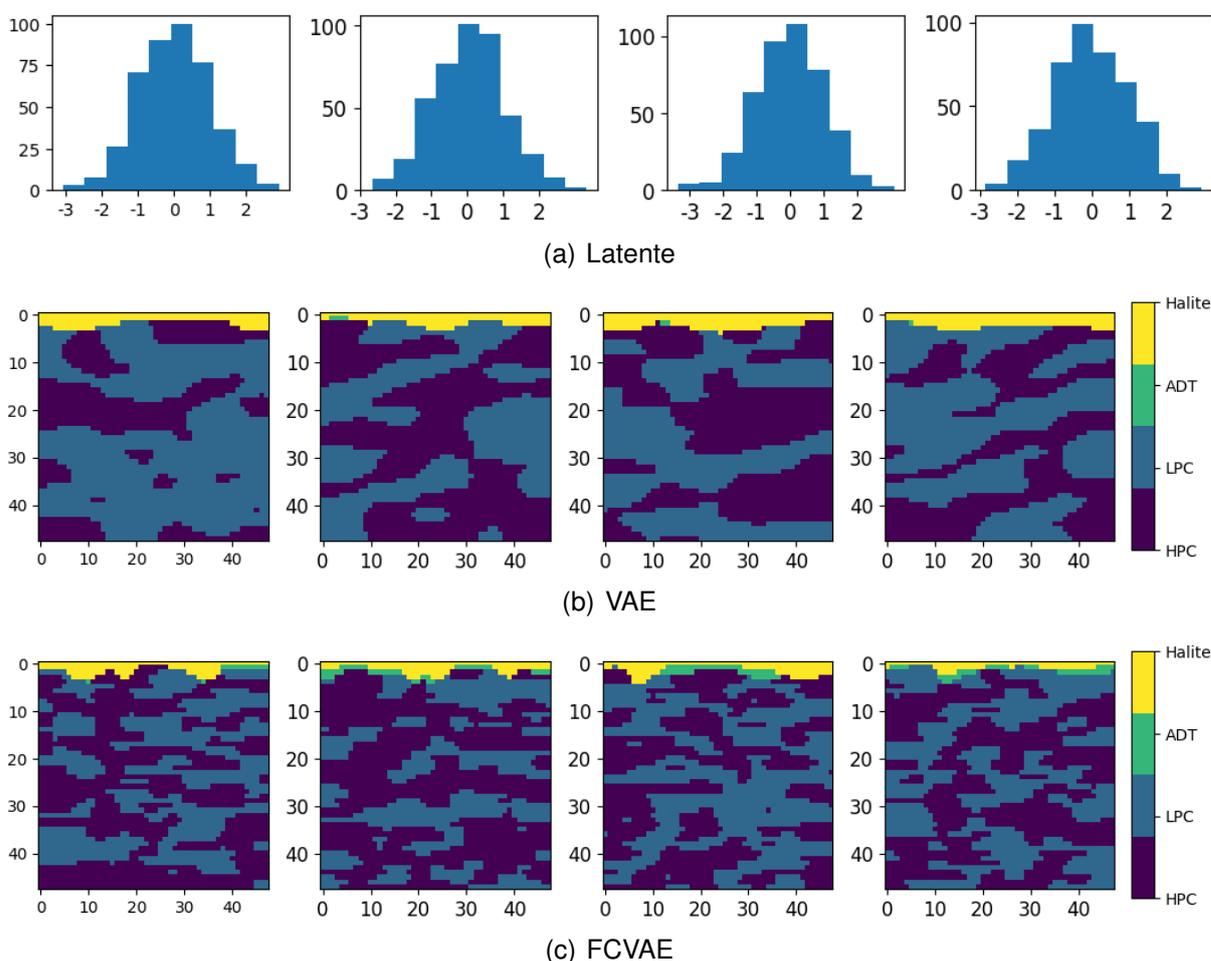


Figura 41 – Exemplos de fácies geradas, a partir de amostras Gaussianas inseridas no espaço latente (a), utilizando o decoder correspondente da VAE (b) e FCVAE (c).

5.2.1.3 Generative Adversarial Net 2D

Utilizando o mesmo conjunto de treinamento de fácies, nesta etapa dos experimentos também foram testadas em duas arquiteturas GANs, uma com camada totalmente conectada (GAN) e outra totalmente convolucional (FCGAN). Ambas foram treinadas durante 500 épocas, utilizando Adam como otimizador.

O treinamento das GANs se difere das VAEs, pois neste caso duas redes são colocadas em um processo de treinamento adversário, onde a parte geradora da GAN é colocada em confronto com a parte discriminadora. Ao final, espera-se que a parte geradora consiga gerar imagens de fácies na qual a discriminadora não consiga diferenciar se a imagem é gerada ou real do conjunto de treinamento.

Durante o processo de treinamento, é possível verificar que a GAN totalmente conectada apresenta o mesmo comportamento da VAE, com a função de erro tendo

uma menor convergência se comparada a GAN totalmente convolucional. A Figura 42 mostra a convergência da função de erro para ambas as GANs.

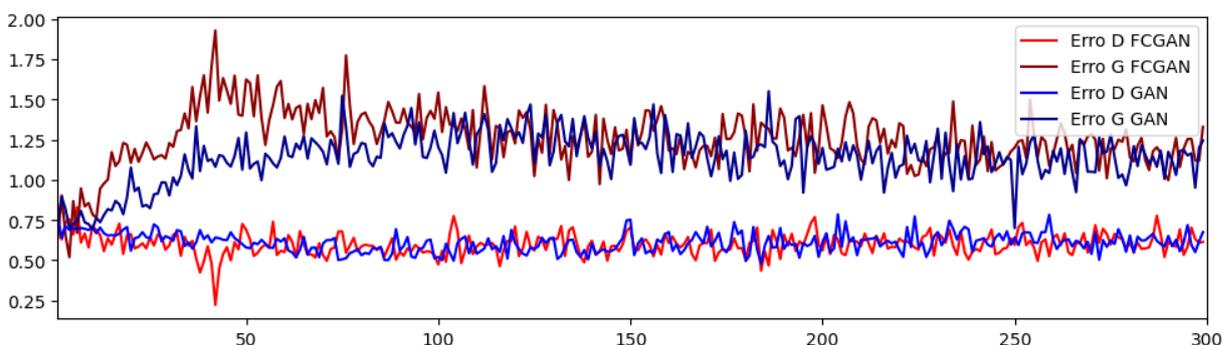


Figura 42 – Função de erro durante o treinamento da GAN e GAN totalmente convolucional propostas neste trabalho.

Durante o treinamento foi observado certa instabilidade na geração de novas fácies a partir de G. Podemos observar que mesmo após 30 mil épocas e utilizando 10 mil amostras de fácies, a GAN teve certa dificuldade em respeitar as ordens das camadas de fácies presentes nas matrizes de transição. Em alguns casos a GAN insere pequenos pontos da fácies Anidrita (ADT) e Halita entre as fácies carbonatos. No entanto, da mesma maneira, após o treinamento, o objetivo é que a parte geradora das GANs consiga gerar imagens de fácies compatíveis com um modelo de fácies gerados a partir das matrizes de transição utilizadas para a criação do conjunto de dados de treinamento. A Figura 43 mostra realizações de fácies geradas pela GAN.

5.2.2 ES-MDA com Redes Generativas para Inversão de Fácies Sísmicas

O processo de inversão de fácies sísmicas é composto do processamento de informações de diferentes domínios, tanto do discreto (fácies) como do contínuo (sísmica). Neste caso, o objetivo deste experimento é utilizar redes do tipo generativas treinadas para reparametrizar as fácies discretas para um espaço regular gaussiano contínuo afim de poderem ser processadas pelo ES-MDA.

5.2.2.1 Fácies Benchmark

Para gerar o modelo de fácies de referência, utilizamos o mesmo processamento que utiliza as matrizes de transição para geração das fácies. Neste caso, foi gerado um modelo de fácies de referência não presente no conjunto de dados para treinamento das redes generativas. Com isso, o objetivo é avaliar também a generalização e capacidade das redes generativas em gerar um modelo similar de fácies, mesmo não sendo apresentada à rede anteriormente.

O modelo de referência também possui tamanho de 48×48 . Para obter a sísmica, foi utilizado o problema direto, ou *forward model*, na qual na sísmica simulada foi adicionada um ruído branco para se aproximar de uma informação real, já que

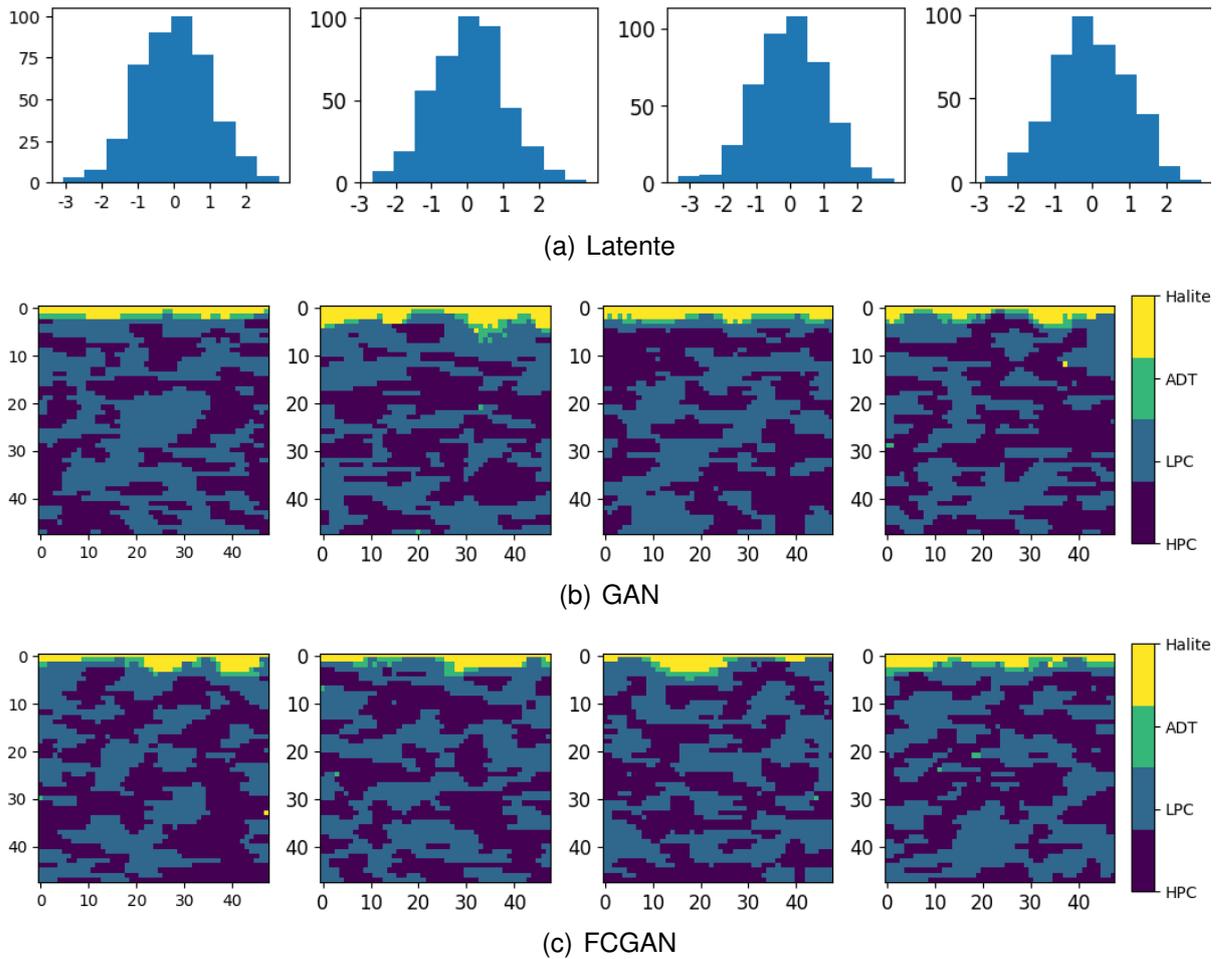


Figura 43 – Exemplos de fácies geradas, a partir de amostras Gaussianas inseridas no espaço latente (a), utilizando a estrutura geradora correspondente da GAN (b) e FCGAN (c).

comumente as sísmicas possuem informações ruidosas. A Figura 44 ilustra o modelo de referência, seguida pela sísmica e a impedância correspondente, utilizada para os experimentos de inversão de fácies sísmicas com ES-MDA integrado com as redes VAE e GAN.

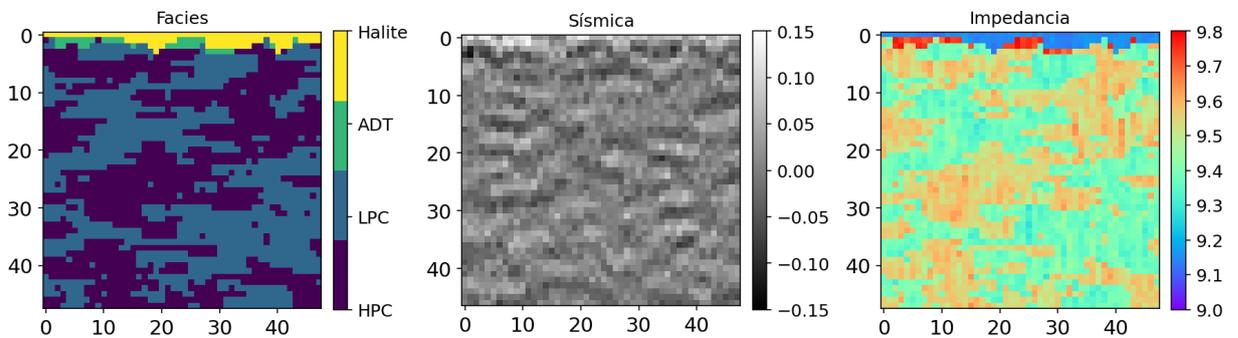


Figura 44 – Modelo de fácies de referência utilizada nos experimentos para reparametrização das fácies com redes generativas.

5.2.2.2 Reparametrização das Fácies e Assimilação da Sísmica 2D

Um dos objetivos deste trabalho é gerar novas amostras de fácies a partir de amostras Gaussianas utilizando as redes generativas treinadas. Como mencionando anteriormente, o Ensemble Smoother não processa dados discretos, por isso existe a necessidade de estratégias para transformar esse tipo de informação em um dado contínuo para que o ES-MDA possa atualizar as variáveis ou parâmetros do modelo de reservatório.

A partir dos modelos generativos treinados, é possível gerar novas realizações de fácies a partir de amostras da distribuição Gaussiana utilizada no espaço latente. No caso da VAE, após o treinamento, é utilizada somente a parte do decoder, ou seja, o espaço z é iniciado com amostras n Gaussianas que serão utilizadas para gerar n novas amostras de fácies. Já para a GAN, a estrutura do discriminador é descartado, pois é necessária somente para treinamento, e utiliza-se somente a estrutura geradora. Da mesma maneira, as n amostras Gaussianas serão a representação para n possíveis realizações de fácies.

Na integração com o ES-MDA, o algoritmo irá atualizar as amostras do espaço latente, ou seja, as amostras gaussianas na qual cada modelo de fácies pode ser reproduzido com o decoder (VAE) ou gerador (GAN). Ou seja, durante a execução, são geradas amostras do espaço latente, um para cada modelo membro do ensemble.

Em ambos os modelos foi possível obter uma redução de até 93% do conjunto de dados original. Esta redução impacta diretamente no tamanho da matriz de cross-covariância C_{md} entre o modelo m e os dados observados d , pois neste caso, o modelo foi reduzido de uma tamanho de 48×48 para um espaço latente de 12×12 . Portanto, a matriz de cross-covariância ficou de tamanho 144×2304 , ou seja, 93,75% menor, aumentando a performance do ES-MDA durante a assimilação dos dados no processo de inversão.

Na execução do ES-MDA, primeiramente é preciso iniciar o ensemble prior, que é composto por possíveis soluções para os parâmetros, as fácies, do modelo *forward* da inversão de fácies sísmicas. Como será utilizada as redes generativas para representar as fácies, o ensemble pode ser inicializado com valores amostrados a partir da Gaussiana. Neste caso, para cada membro do ensemble, uma amostra do espaço latente precisa ser gerada. Nestes experimentos, foi utilizada um ensemble de tamanho 1000, ou seja, fora geradas 1000 amostras gaussianas compatíveis com a dimensão do espaço latente das redes, uma para cada fácies. A Figura 45 mostra os três primeiros modelos do ensemble e a fácies correspondente reconstruída utilizando o decoder da VAE.

Durante o processo de assimilação e atualização do ensemble, a parte decodificadora ou gerados das redes são chamadas somente para recuperar as fácies, executa o *forward* model e obter a sísmica simulada, pois o ES-MDA recebe somente as a-

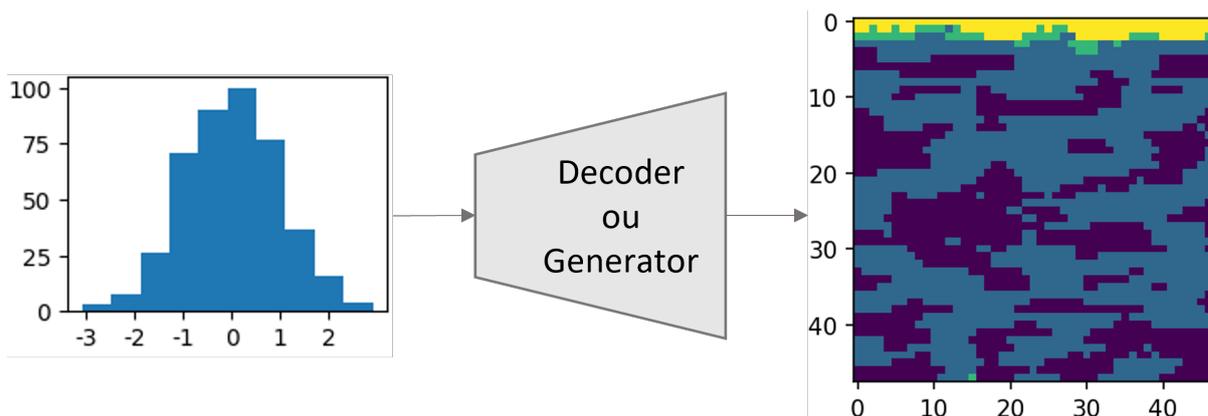


Figura 45 – Geração do ensemble inicial a partir de amostras gaussianas.

mostras latentes. Portanto, a matriz de covariância C_{md} será calculada com m sendo as amostras Gaussianas e d o dado sísmico assimilado. Neste caso, o tamanho das amostras m influencia diretamente no tamanho de C_{md} , quanto menor for m , maior será a performance do processo de atualização do ensemble, devido a menor quantidade de dados a serem processados.

Os experimentos realizados com ambos os tipos de redes generativas mostram que ambas obtiveram resultados similares em questão de tempo de execução e erro em relação ao modelos de fácies de referência. No ES-MDA os dados de sísmica foram assimilados 50 vezes, ou seja, o ensemble de possíveis soluções foi atualizado por 50 vezes durante o processo iterativo. Utilizando a VAE, o erro em relação ao modelo de fácies de referência reduziu mais rápido do que quando foi utilizado a GAN. No entanto, ao final ambas obtiveram resultados similares, onde a VAE obteve uma acurácia de 82% e a GAN de 78%. Na Figura 46 é mostrado o resultado do ES-MDA com VAE e na Figura 47 o resultado com ES-MDA integrado com GAN.

Visualmente, o resultado final se mostrou satisfatório, porém em alguns pontos a GAN inseriu tipos de fácies que não respeitam as matrizes de transição P_v e P_h . A Figura 48 ilustra o gráfico com a convergência do erro para a VAE e a FCVAE, a Figura 49 da GAN e FCGAN e a Figura 50 ilustra os resultados de todas as integrações do ES-MDA com VAE, FCVAE, GAN e FCGAN.

5.3 DISCUSSÃO

A metodologia proposta neste trabalho envolveu a integração de redes profundas com o ES-MDA para resolver dois problemas de inversão para caracterização de reservatórios, o ajuste de histórico e inversão de fácies sísmicas. Para cada problema, um tipo de rede profunda é designada para a solução, no caso do ajuste de histórico, as redes autoencoder são utilizadas para reduzir os dados da sísmica 4D simuladas e observadas. Já para a inversão de fácies sísmicas, as redes generativas são utilizadas para representação das fácies em um espaço latente reduzido.

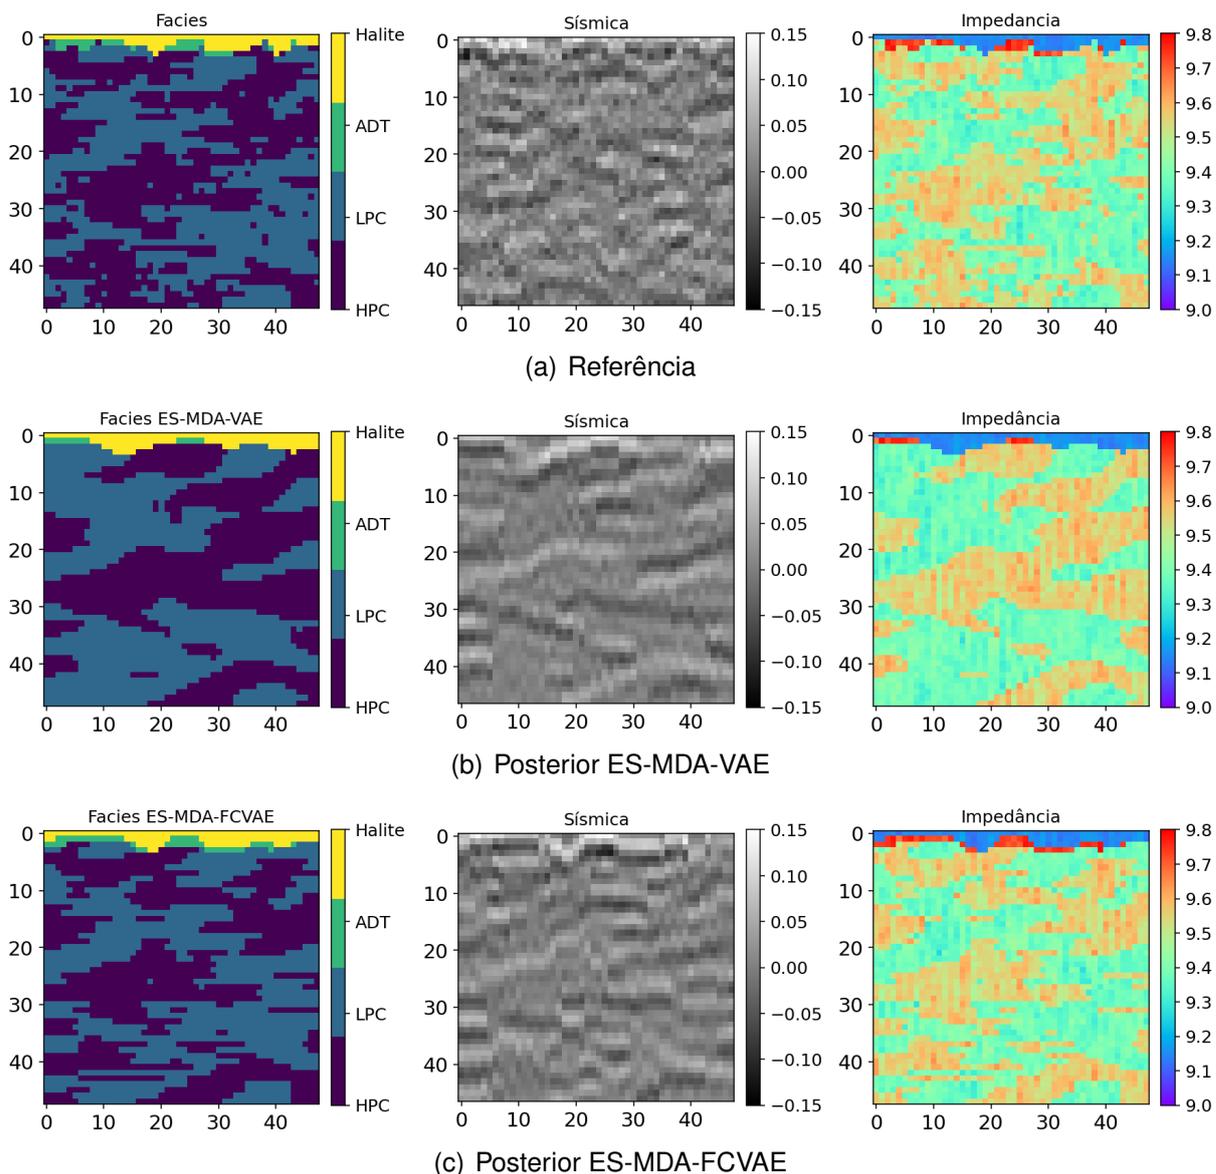


Figura 46 – Resultado obtidos com ES-MDA e a reparametrização das fácies com VAE, onde (a) é o modelo de referência, (b) o início do processo de inversão e (c) as fácies obtidas após 20 iterações.

Durante a integração com o ES-MDA, ambas as abordagens obtiveram resultado satisfatórios, destacando a redução da quantidade de informação a ser processado pelo ES-MDA e a acurácia utilizando estruturas das redes do tipo totalmente convolucional. A partir dos experimentos preliminares pode-se observar que o Ensemble Smoother é capaz de trabalhar diretamente nas informações extraídas pelas redes neurais profundas, tanto em relação aos dados observados como nos parâmetros do modelo. Apesar das limitações do Ensemble Smoother em relação às premissas dos modelos geológicos serem representadas somente por Gaussianas e a utilização de exclusiva de variáveis contínuas, as abordagens de integração do ES-MDA com redes profundas como autoencoders e modelos generativos se mostrou promissora, tanto na aplicação de reparametrização das fácies, como a redução dimensional da sísmica.

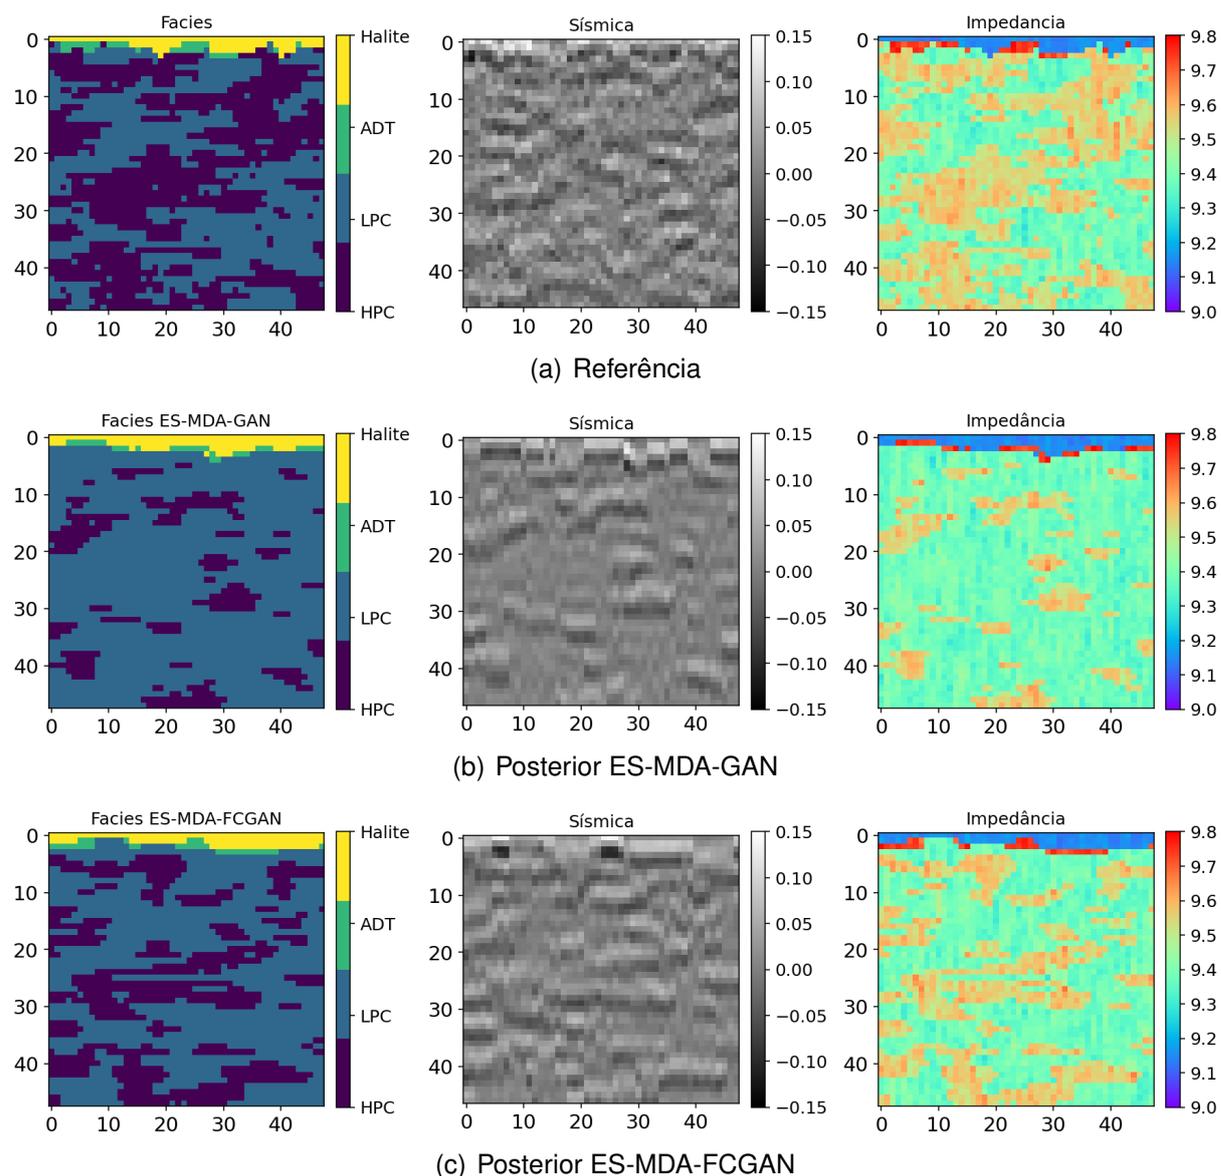


Figura 47 – Resultado obtidos com ES-MDA e a reparametrização das fácies com GAN, onde (a) é o modelo de referência, (b) o início do processo de inversão e (c) as fácies obtidas após 20 iterações.

No experimentos com ajuste de histórico, para o treinamento das redes autoencoders aproveitou-se a utilidade de reutilização dos pesos de uma rede pré-treinada com imagens naturais para o domínio da sísmica. Com isso, a técnica de transfer learning se torna útil para reduzir o tempo de treinamento e fazer a extração de características de imagens de sísmica 4D. Portanto, a integração do autoencoder com o ES-MDA é feita rapidamente, sem a necessidade de retreinamento de toda a rede neural, além de fazer a redução significativa na quantidade de dados a serem processados pelo ES-MDA, exigindo menor tempo de processamento e também menos recursos computacionais, principalmente memória.

Outra metodologia foi a reparametrização das fácies, fazendo com que elas sejam representadas por Gaussianas em um espaço reduzido via variáveis latentes dos

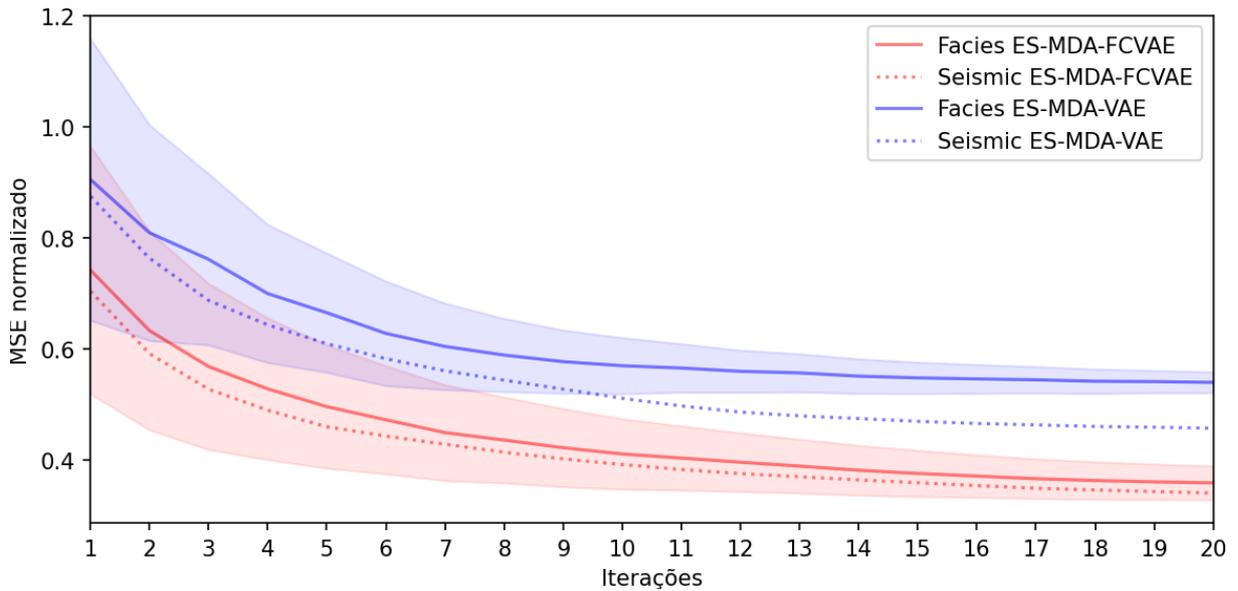


Figura 48 – Convergência do erro com ES-MDA-VAE e ES-MDA-FCVAE durante 20 iterações.

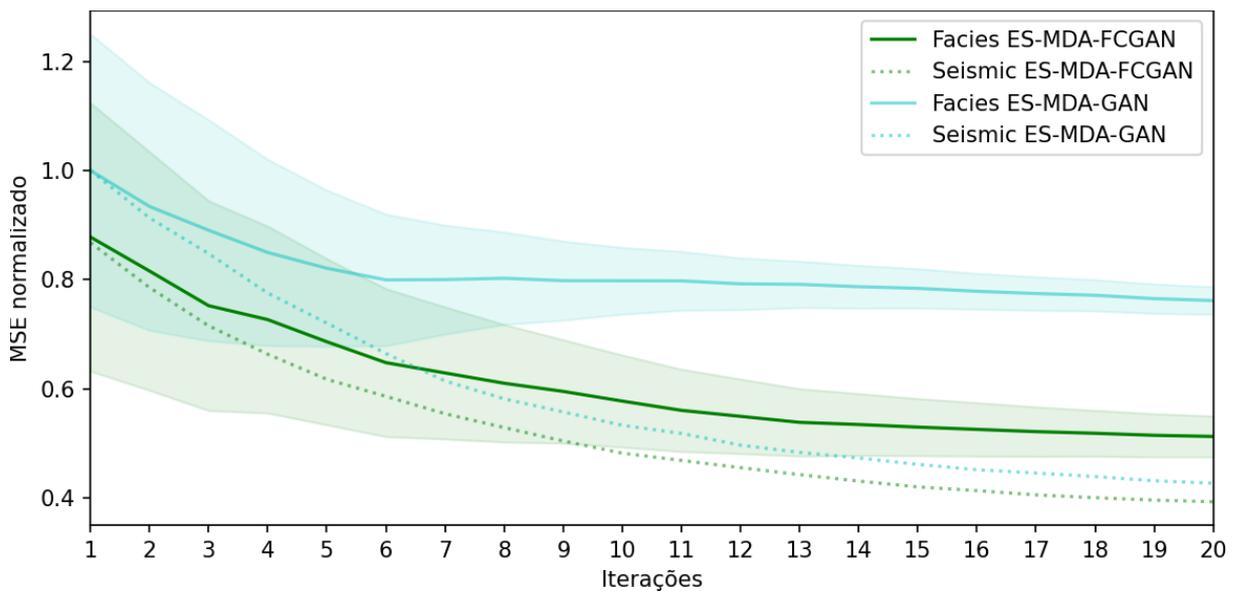


Figura 49 – Convergência do erro com ES-MDA-GAN e ES-MDA-FCGAN durante 20 iterações.

modelos generativos e assimilar a sísmica durante o processo iterativo do ES-MDA. Apesar das características das fácies do pré-sal, onde se tem bem definido a região e sequência em que cada fácies é formada, durante o treinamento dos modelos generativos, pode-se observar que as redes conseguiram respeitar de maneira satisfatória as regras e restrições presentes nas matrizes de transições P_v e P_h entre as fácies.

Apesar dos modelos generativos precisarem de um conjunto de treinamento, utilizando Cadeias de Markov foi possível gerar uma grande quantidade de amostras de fácies sintéticas, mas com estatísticas retiradas de um reservatório real do pré-sal. Outro ponto importante é que, após os modelos generativos serem treinados, a utilização da estrutura decoder para a obtenção de novas amostras de fácies tem uma

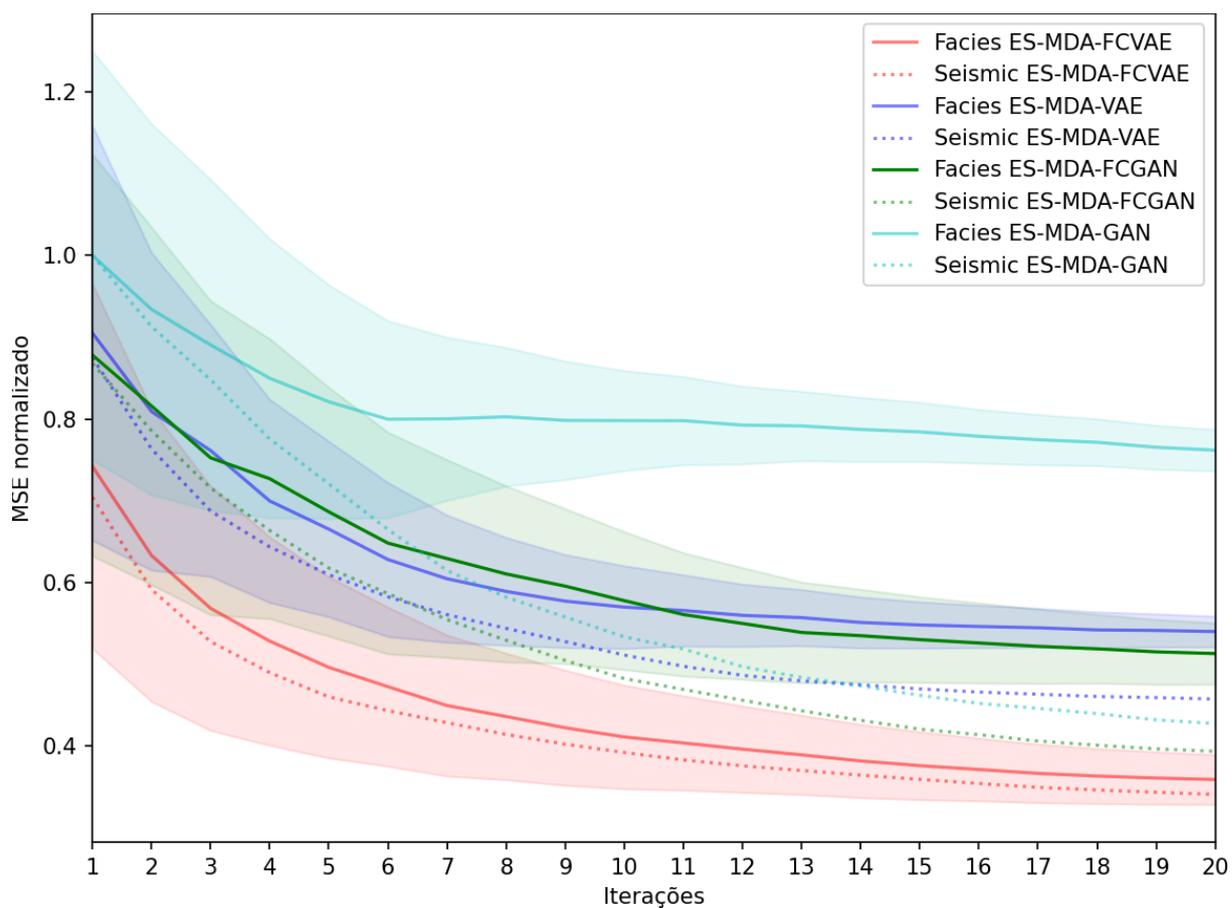


Figura 50 – Convergência do erro do ES-MDA-VAE, ES-MDA-FCVAE, ES-MDA-GAN e ES-MDA-FCGAN durante 20 iterações.

performance superior, com menor tempo de geração ou inferência se comparada às Cadeias de Markov.

Dentre as vantagens da utilização de modelos generativos para reparametrizar as fácies esta a redução dimensional dos parâmetros do modelo forward a serem estimados, com isso, nos testes preliminares, foi possível uma redução de aproximadamente 94% na dimensão das fácies a serem estimadas, reduzindo significativamente as matrizes de covariância do ES-MDA.

Um dos diferenciais dos modelos generativos deste trabalho é a utilização de somente camadas convolucionais nas arquiteturas das redes. Além de reduzir a quantidade de parâmetros dos modelos, isto faz com que as características espacialmente correlacionadas sejam preservadas em todas as camadas da rede, ajudando em novas abordagens para o problema de localização do Ensemble Smoother. Neste caso, cada posição da variável do espaço latente está correlacionada diretamente com a posição dos dados de entrada, ou seja, como z é uma matriz, cada índice da matriz influencia somente na região daquele índice na imagem de entrada.

Devido a capacidade de redução dimensional dos modelos generativos, um dos testes será a comparação entre o nível de redução de z e o aumento do tamanho

do ensemble. Neste caso, a medida que z é reduzido, o número da quantidade do ensemble pode ser aumentando sem a perda demasiada de desempenho. No entanto, quanto mais z é reduzido, maior será o erro da reconstrução pela rede, pois tem-se menos variáveis para representar o espaço original das fácies. Porém, isto permite o ES-MDA trabalhar com um ensemble maior, tendo mais modelos possíveis de solução para a inversão. Portanto, será interessante observar esta relação entre a redução de z com o aumento de N_e na performance de execução e nos resultados do ES-MDA.

6 CONCLUSÃO

Neste trabalho foi proposta uma nova metodologia para a integração de redes neurais profundas com Ensemble Smoother with Multiple Data Assimilation aplicadas para a caracterização de reservatórios em dois problemas inversos: ajuste de histórico e inversão de fácies sísmicas. Duas inovações principais se destacam, a utilização de *transfer-learning* e as arquiteturas desenvolvidas das redes neurais profundas baseadas principalmente em camadas totalmente convolucionais.

Para o problema de ajuste de histórico, as redes neurais utilizadas foram do tipo autoencoders, incluindo suporte à entradas 2D e 3D, para a extração de características das sísmicas 4D e utilizar essas características durante o processo de assimilação executado pelo ES-MDA. A abordagem foi comparada com o ES-MDA tradicional, onde os resultados mostram compatibilidade da redução do erro entre o dado observado e o dado simulado quando os autoencoders são utilizados. Apesar do erro em relação a função objetiva ser ligeiramente mais alto do que o ES-MDA tradicional, o tempo de execução é de até 90% menor para reservatórios de maior dimensionalidade, dada a redução na quantidade de dados a serem processados durante a execução do ES-MDA. Com isso, a proposta se mostrou robusta e torna possível a aplicação do ES-MDA para reservatórios de grande dimensionalidade, na qual anteriormente não seria possível.

Na abordagem para a inversão de fácies sísmicas, as redes utilizadas foram do tipo generativas, pois como o processamento é em relação aos parâmetros do modelo de entrada do *forward model*, em um dos passos é necessário gerar o ensemble via rede neural para ser passível de integração com o ES-MDA. Neste caso, utilizamos somente dados no formato 2D e duas redes neurais, a Variational Autoencoder e Generative Adversarial Net. Ambas foram treinadas e integradas no ES-MDA para reparametrizar os dados discretos, ou categóricos, de fácies em um espaço reduzido e gaussiano, já que o ES-MDA assume que os modelos possuem relação gaussiana. Os resultados mostram que ambas as redes neurais VAE e GAN com arquitetura totalmente convolucional obtiveram melhores resultados se comparada as VAE e GANs tradicionais que possuíam camadas totalmente conectadas. Ao final, utilizando o ES-MDA, as fácies de referência foram estimadas com um erro menor utilizando as redes totalmente convolucionais e a convergência se mostrou mais estável.

Dentre os trabalhos futuros, pode explorar a junção dos dois métodos de inversão, incluindo as fácies também no processo de ajuste histórico. Além disso modelos baseados em Vision Transformers e outras arquiteturas autoencoders podem ser exploradas na integração com o ES-MDA. Já para o problema de inversão de fácies sísmicas, neste trabalho foi utilizada dados 2D, na qual modelos 3D podem ser explorados afim de obter melhores resultados para reservatórios tridimensionais. Em ambos os casos, trabalhos para a comparação entre os diferentes níveis de profundidade das redes com

diferentes tamanhos de reduções e comparação do uso de memória no processo de assimilação de dados pode ser explorado.

7 PUBLICAÇÕES

Durante o curso de Doutorado em Ciência da Computação pelo Programa de Pós-Graduação e Ciência da Computação - UFSC foram publicados os seguinte trabalhos:

- SICLAP-P - A1 - Exterkoetter, Rodrigo, Dutra, Gustavo R., de Figueiredo, Leandro P., Bordignon, Fernando, Neto, Gilson M. S., and Alexandre A. Emerick. Feature Extraction in Time-Lapse Seismic Using Deep Learning for Data Assimilation. *SPE Journal* 29 (2024): 2014–2025.
- SICLAP-E - A1 - Exterkoetter, R., Dutra, G. R., de Figueiredo, L. P., Bordignon, F. L., Emerick, A. A., Neto, G. M. S., & Roisenberg, M. (2023, June). Deep Feature Extraction for Data Assimilation with Ensemble Smoother. In *2023 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
- SICLAP-P - A1 - Exterkoetter, R., de Figueiredo, L. P., Bordignon, F. L., Emerick, A. A., Roisenberg, M., & Rodrigues, B. B. (2024). Ensemble smoother with fully convolutional VAE for seismic facies inversion. *Computers & Geosciences*, 105619.

REFERÊNCIAS

- AANONSEN, Sigurd I *et al.* The ensemble Kalman filter in reservoir engineering—a review. **Spe Journal**, OnePetro, v. 14, n. 03, p. 393–412, 2009. Citado nas pp. [15](#), [17](#), [27](#).
- ALBELWI, Saleh; MAHMOOD, Ausif. A framework for designing the architectures of deep convolutional neural networks. **Entropy**, Multidisciplinary Digital Publishing Institute, v. 19, n. 6, p. 242, 2017. Citado nas pp. [8](#), [35](#).
- ALMOTIRI, Jasem; ELLEITHY, Khaled; ELLEITHY, Abdelrahman. Comparison of autoencoder and Principal Component Analysis followed by neural network for e-learning using handwritten recognition. *In: IEEE. 2017 IEEE Long Island Systems, Applications and Technology Conference (LISAT). [S.l.: s.n.], 2017. P. 1–5. Citado na p. [47](#).*
- ALQAHTANI, Naif J *et al.* Flow-based characterization of digital rock images using deep learning. **SPE Journal**, OnePetro, v. 26, n. 04, p. 1800–1811, 2021. Citado na p. [45](#).
- ARJOVSKY, Martin; CHINTALA, Soumith; BOTTOU, Léon. Wasserstein gan. **arXiv preprint arXiv:1701.07875**, 2017. Citado na p. [48](#).
- AVANSI, Guilherme Daniel; MASCHIO, Célio; SCHIOZER, Denis José. Simultaneous history-matching approach by use of reservoir-characterization and reservoir-simulation studies. **SPE Reservoir Evaluation & Engineering**, SPE, v. 19, n. 04, p. 694–712, 2016. Citado na p. [23](#).
- BAMNE, Bulbul *et al.* Transfer learning-based object detection by using convolutional neural networks. *In: IEEE. 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC). [S.l.: s.n.], 2020. P. 328–332. Citado na p. [45](#).*
- BULAND, Arild; OMRE, Henning. Bayesian linearized AVO inversion. **Geophysics**, Society of Exploration Geophysicists, v. 68, n. 1, p. 185–198, 2003. Citado na p. [17](#).
- CAERS, Jef; ZHANG, Tuanfeng. Multiple-point geostatistics: a quantitative vehicle for integrating geologic analogs into multiple reservoir models. AAPG Special Volumes, 2004. Citado na p. [15](#).

CANCHUMUNI, Smith Arauco; EMERICK, Alexandre A; PACHECO, Marco Aurelio. Integration of ensemble data assimilation and deep learning for history matching facies models. *In: OTC. OFFSHORE Technology Conference Brasil*. [S.l.: s.n.], 2017. d011s006r005. Citado nas pp. [17](#), [29](#), [30](#), [46](#).

CANCHUMUNI, Smith WA; EMERICK, Alexandre A; PACHECO, Marco Aurélio C. Towards a robust parameterization for conditioning facies models using deep variational autoencoders and ensemble smoother. **Computers & Geosciences**, Elsevier, v. 128, p. 87–102, 2019. Citado nas pp. [9](#), [17](#), [18](#), [47–49](#).

CANCHUMUNI, Smith WA *et al.* Recent developments combining ensemble smoother and deep generative networks for facies history matching. **Computational Geosciences**, Springer, v. 25, n. 1, p. 433–466, 2021. Citado nas pp. [17](#), [18](#), [29](#), [48](#).

DENG, Jia *et al.* Imagenet: A large-scale hierarchical image database. *In: IEEE. 2009 IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2009. P. 248–255. Citado na p. [50](#).

DENG, Li. The mnist database of handwritten digit images for machine learning research. **IEEE Signal Processing Magazine**, IEEE, v. 29, n. 6, p. 141–142, 2012. Citado na p. [63](#).

EMERICK, Alexandre; REYNOLDS, Albert. Combining sensitivities and prior information for covariance localization in the ensemble Kalman filter for petroleum reservoir applications. **Computational Geosciences**, Springer, v. 15, p. 251–269, 2011. Citado nas pp. [27](#), [29](#).

EMERICK, Alexandre A. Analysis of geometric selection of the data-error covariance inflation for ES-MDA. **Journal of Petroleum Science and Engineering**, Elsevier, v. 182, p. 106168, 2019. Citado na p. [23](#).

EMERICK, Alexandre A. Investigation on principal component analysis parameterizations for history matching channelized facies models with ensemble-based data assimilation. **Mathematical Geosciences**, Springer, v. 49, n. 1, p. 85–120, 2017. Citado na p. [47](#).

EMERICK, Alexandre A; REYNOLDS, Albert C. Ensemble smoother with multiple data assimilation. **Computers & Geosciences**, Elsevier, v. 55, p. 3–15, 2013. Citado nas pp. [17](#), [27](#), [30](#), [55](#).

EMERICK, Alexandre A; REYNOLDS, Albert C. History matching time-lapse seismic data using the ensemble Kalman filter with multiple data assimilations. **Computational Geosciences**, Springer, v. 16, p. 639–659, 2012. Citado nas pp. [16](#), [17](#), [27](#).

EMERICK, Alexandre A; REYNOLDS, Albert C. Investigation of the sampling performance of ensemble-based methods with a simple reservoir model. **Computational Geosciences**, Springer, v. 17, n. 2, p. 325–350, 2013. Citado na p. [30](#).

EMERICK, Alexandre Anozé; MORAES, Rafael Jesus de; RODRIGUES, José Roberto Pereira. History matching 4D seismic data with efficient gradient based methods. *In: SPE. SPE Europec featured at EAGE Conference and Exhibition?* [S.l.: s.n.], 2007. spe–107179. Citado nas pp. [17](#), [22](#).

EVENSEN, Geir *et al.* **Data assimilation: the ensemble Kalman filter**. [S.l.]: Springer, 2009. v. 2. Citado nas pp. [27](#), [28](#).

EVENSEN, Geir; VOSSEPOEL, Femke C; LEEUWEN, Peter Jan van. **Data assimilation fundamentals: A unified formulation of the state and parameter estimation problem**. [S.l.]: Springer Nature, 2022. Citado na p. [27](#).

EXTERKOETTER, Rodrigo *et al.* Petroleum Reservoir Connectivity Patterns Reconstruction Using Deep Convolutional Generative Adversarial Networks. *In: IEEE. 2018 7th Brazilian Conference on Intelligent Systems (BRACIS)*. [S.l.: s.n.], 2018. P. 97–102. Citado nas pp. [8](#), [37](#).

FAHIMUDDIN, Abul; AANONSEN, Sigurd Ivar; SKJERVHEIM, J-A. Ensemble based 4D seismic history matching: Integration of different levels and types of seismic data. *In: SPE. SPE Europec featured at EAGE Conference and Exhibition?* [S.l.: s.n.], 2010. spe–131453. Citado na p. [46](#).

FIGUEIREDO, L Passos de; RODRIGUES, BB *et al.* Bayesian elastic facies inversion applied to Lula field. *In: EUROPEAN ASSOCIATION OF GEOSCIENTISTS & ENGINEERS, 1. FIRST EAGE Workshop on Pre-Salt Reservoir: from Exploration to Production*. [S.l.: s.n.], 2019. P. 1–5. Citado nas pp. [10](#), [17](#), [46](#), [55](#), [72](#).

FIGUEIREDO, Leandro Passos de; GRANA, Dario; BORDIGNON, Fernando Luis *et al.* Joint Bayesian inversion based on rock-physics prior modeling for the estimation of spatially correlated reservoir properties. **Geophysics**, Society of Exploration Geophysicists, v. 83, n. 5, p. m49–m61, 2018. Citado nas pp. [26](#), [27](#).

FIGUEIREDO, Leandro Passos de; GRANA, Dario; SANTOS, Marcio *et al.* Bayesian seismic inversion based on rock-physics prior modeling for the joint estimation of acoustic impedance, porosity and lithofacies. **Journal of Computational Physics**, Elsevier, v. 336, p. 128–142, 2017. Citado nas pp. [17](#), [21](#).

FLORIS, Frans JT *et al.* Methods for quantifying the uncertainty of production forecasts: a comparative study. **Petroleum Geoscience**, Geological Society of London, v. 7, S, s87–s96, 2001. Citado nas pp. [64](#), [65](#).

GATYS, Leon A; ECKER, Alexander S; BETHGE, Matthias. Image style transfer using convolutional neural networks. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. P. 2414–2423. Citado na p. [49](#).

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. [S.l.]: MIT press, 2016. Citado nas pp. [8](#), [9](#), [32–38](#), [40](#), [41](#).

GOODFELLOW, Ian; POUGET-ABADIE, Jean *et al.* Generative adversarial nets. *In: ADVANCES in neural information processing systems*. [S.l.: s.n.], 2014. P. 2672–2680. Citado nas pp. [39–41](#), [55](#), [57](#).

GOSSELIN, O e *et al.* History matching using time-lapse seismic (HUTS). *In: SPE. SPE Annual Technical Conference and Exhibition?* [S.l.: s.n.], 2003. spe–84464. Citado nas pp. [23](#), [24](#).

GRANA, Dario. Bayesian linearized rock-physics inversion. **Geophysics**, Society of Exploration Geophysicists, v. 81, n. 6, p. d625–d641, 2016. Citado nas pp. [15](#), [46](#).

GRANA, Dario. Joint facies and reservoir properties inversion. **Geophysics**, Society of Exploration Geophysicists, v. 83, n. 3, p. m15–m24, 2018. Citado nas pp. [16](#), [26](#), [55](#).

GRANA, Dario; AZEVEDO, Leonardo *et al.* Probabilistic inversion of seismic data for reservoir petrophysical characterization: Review and examples. **Geophysics**, Society of Exploration Geophysicists, v. 87, n. 5, p. m199–m216, 2022. Citado na p. [67](#).

GRANA, Dario; FIGUEIREDO, Leandro Passos de; PESCO, Sinesio *et al.* Uncertainty quantification in seismic facies inversion. **Geophysics**, GeoScienceWorld, v. 85, n. 4, p. m43–m56, 2020. Citado nas pp. [26](#), [27](#).

GRANA, Dario; FJELDSTAD, Torstein; OMRE, Henning. Bayesian Gaussian mixture linear inversion for geophysical inverse problems. **Mathematical Geosciences**, Springer, v. 49, n. 4, p. 493–515, 2017. Citado na p. 17.

GRANA, Dario; MUKERJI, Tapan; DOYEN, Philippe. **Seismic reservoir modeling: Theory, examples, and algorithms**. [S.l.]: John Wiley & Sons, 2021. Citado nas pp. 21, 28.

GRANA, Dario; MUKERJI, Tapan; DVORKIN, Jack *et al.* Stochastic inversion of facies from seismic data based on sequential simulations and probability perturbation method. **Geophysics**, Society of Exploration Geophysicists, v. 77, n. 4, p. m53–m72, 2012. Citado na p. 17.

HAYKIN, Simon. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice Hall PTR, 1994. Citado na p. 31.

HOUTEKAMER, Peter L; MITCHELL, Herschel L. A sequential ensemble Kalman filter for atmospheric data assimilation. **Monthly Weather Review**, American Meteorological Society, v. 129, n. 1, p. 123–137, 2001. Citado na p. 49.

HUANG, Xuri; MEISTER, Laurent; WORKMAN, Rick. Reservoir characterization by integration of time-lapse seismic and production data. *In*: SPE. SPE Annual Technical Conference and Exhibition? [S.l.: s.n.], 1997. spe–38695. Citado na p. 23.

KALCHBRENNER, Ilya; GREFENSTETTE, Edward; BLUNSON, Phil. A convolutional neural network for modelling sentences. **arXiv preprint arXiv:1404.2188**, 2014. Citado na p. 32.

KEMPER, Michael; GUNNING, James. Joint impedance and facies inversion–seismic inversion redefined. **First Break**, European Association of Geoscientists & Engineers, v. 32, n. 9, 2014. Citado na p. 26.

KIM, Yoon. Convolutional neural networks for sentence classification. **arXiv preprint arXiv:1408.5882**, 2014. Citado na p. 32.

KINGMA, Diederik P; BA, Jimmy. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014. Citado na p. 62.

KINGMA, Diederik P; WELING, Max. An introduction to variational autoencoders. **arXiv preprint arXiv:1906.02691**, 2019. Citado na p. 39.

KOHONEN, Teuvo *et al.* Springer-Verlag New York. **Inc., Secaucus, NJ**, v. 43, p. 2, 2001. Citado na p. 31.

KORJANI, M *et al.* A new approach to reservoir characterization using deep learning neural networks. *In: SOCIETY OF PETROLEUM ENGINEERS. SPE Western Regional Meeting.* [S.l.: s.n.], 2016. Citado na p. 17.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. *In: ADVANCES in neural information processing systems.* [S.l.: s.n.], 2012. P. 1097–1105. Citado na p. 32.

KULLBACK, Solomon; LEIBLER, Richard A. On information and sufficiency. **The annals of mathematical statistics**, JSTOR, v. 22, n. 1, p. 79–86, 1951. Citado na p. 39.

LACERDA, Johann M; EMERICK, Alexandre A; PIRES, Adolfo P. Methods to mitigate loss of variance due to sampling errors in ensemble data assimilation with non-local model parameters. **Journal of Petroleum Science and Engineering**, Elsevier, v. 172, p. 690–706, 2019. Citado na p. 49.

LE, Duc H; YOUNIS, Rami; REYNOLDS, Albert C *et al.* A history matching procedure for non-Gaussian facies based on ES-MDA. *In: SOCIETY OF PETROLEUM ENGINEERS. SPE Reservoir Simulation Symposium.* [S.l.: s.n.], 2015. Citado na p. 16.

LECUN, Yann *et al.* Backpropagation applied to handwritten zip code recognition. **Neural computation**, MIT Press, v. 1, n. 4, p. 541–551, 1989. Citado na p. 32.

LIN, Tsung-Yi *et al.* Microsoft coco: Common objects in context. *In: SPRINGER. EUROPEAN conference on computer vision.* [S.l.: s.n.], 2014. P. 740–755. Citado na p. 61.

LIU, Mingliang; GRANA, Dario. Ensemble-based seismic history matching with data reparameterization using convolutional autoencoder. *In: SEG Technical Program Expanded Abstracts 2018.* [S.l.]: Society of Exploration Geophysicists, 2018. P. 3156–3160. Citado na p. 27.

LIU, Mingliang; GRANA, Dario. Stochastic nonlinear inversion of seismic data for the estimation of petroelastic properties using the ensemble smoother and data reparameterization. **Geophysics**, Society of Exploration Geophysicists, v. 83, n. 3, p. m25–m39, 2018. Citado nas pp. 18, 30, 44, 55.

LIU, Mingliang; GRANA, Dario. Time-lapse seismic history matching with an iterative ensemble smoother and deep convolutional autoencoder. **Geophysics**, Society of Exploration Geophysicists, v. 85, n. 1, p. m15–m31, 2020. Citado nas pp. [9](#), [17](#), [18](#), [23](#), [27](#), [29](#), [45](#).

LIU, Yimin; DURLOFSKY, Louis J. Multilevel strategies and geological parameterizations for history matching complex reservoir models. **SPE Journal**, OnePetro, v. 25, n. 01, p. 081–104, 2020. Citado na p. [45](#).

LONG, Jonathan; SHELHAMER, Evan; DARRELL, Trevor. Fully convolutional networks for semantic segmentation. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. P. 3431–3440. Citado nas pp. [18](#), [32](#), [38](#).

LUMLEY, DE; BEHRENS, RA. Practical issues of 4D seismic reservoir monitoring: What an engineer needs to know. **SPE Reservoir Evaluation & Engineering**, OnePetro, v. 1, n. 06, p. 528–538, 1998. Citado nas pp. [23](#), [24](#).

MA, Yongsheng *et al.* Reservoir characterization using seismic data after frequency bandwidth enhancement. **Journal of Geophysics and Engineering**, Elsevier, v. 2, n. 3, p. 213, 2005. Citado na p. [21](#).

OLIVER, Dean S; FOSSUM, Kristian *et al.* 4D seismic history matching. **Journal of Petroleum Science and Engineering**, Elsevier, v. 207, p. 109119, 2021. Citado na p. [23](#).

OLIVER, Dean S; REYNOLDS, Albert C; LIU, Ning. **Inverse theory for petroleum reservoir characterization and history matching**. [S.l.: s.n.], 2008. Citado na p. [28](#).

PAN, Sinno Jialin; YANG, Qiang. A survey on transfer learning. **IEEE Transactions on knowledge and data engineering**, IEEE, v. 22, n. 10, p. 1345–1359, 2009. Citado na p. [41](#).

RADFORD, Alec; METZ, Luke; CHINTALA, Soumith. Unsupervised representation learning with deep convolutional generative adversarial networks. **arXiv preprint arXiv:1511.06434**, 2015. Citado na p. [41](#).

RAEESI, Morteza *et al.* Classification and identification of hydrocarbon reservoir lithofacies and their heterogeneity using seismic attributes, logs data and artificial

neural networks. **Journal of Petroleum Science and engineering**, Elsevier, v. 82, p. 151–165, 2012. Citado na p. 17.

ROSCA, Mihaela *et al.* Variational approaches for auto-encoding generative adversarial networks. **arXiv preprint arXiv:1706.04987**, 2017. Citado na p. 48.

RUMELHART, DE; HINTON, GE; WILLIAMS, RJ. **Learning internal representations by error propagation**, **Parallel Distributed Processing**, vol. 1, 318-362. [S.l.]: MIT Press, Cambridge, 1986. Citado na p. 31.

SANCEVERO, Sérgio Sacani *et al.* Aplicação de técnicas de estatística multivariada na definição da litologia a partir de perfis geofísicos de poços. **Revista Brasileira de Geociências**, Sociedade Brasileira de Geologia, v. 38, n. 1, p. 61–74, 2008. Citado nas pp. 15, 21, 22.

SAUSSUS, Denis; SAMS, Mark. Facies as the key to using seismic inversion for modelling reservoir properties. **First Break**, European Association of Geoscientists & Engineers, v. 30, n. 7, 2012. Citado na p. 26.

SEN, Mrinal K; STOFFA, Paul L. **Global optimization methods in geophysical inversion**. [S.l.]: Cambridge University Press, 2013. Citado nas pp. 15, 22.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014. Citado na p. 50.

TARANTOLA, Albert. **Inverse problem theory and methods for model parameter estimation**. [S.l.]: siam, 2005. v. 89. Citado nas pp. 15, 20.

TOO, Edna Chebet *et al.* A comparative study of fine-tuning deep learning models for plant disease identification. **Computers and Electronics in Agriculture**, Elsevier, v. 161, p. 272–279, 2019. Citado na p. 42.

WEISS, Karl; KHOSHGOFTAAR, Taghi M; WANG, DingDing. A survey of transfer learning. **Journal of Big data**, Springer, v. 3, p. 1–40, 2016. Citado na p. 41.

WEN, Long *et al.* A new transfer learning based on VGG-19 network for fault diagnosis. *In*: IEEE. 2019 IEEE 23rd international conference on computer supported cooperative work in design (CSCWD). [S.l.: s.n.], 2019. P. 205–209. Citado na p. 45.

ZHANG, Quanshi; WU, Ying Nian; ZHU, Song-Chun. Interpretable convolutional neural networks. *In: THE IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2018. P. 8827–8836. Citado na p. 32.

ZHU, Jun-Yan *et al.* Unpaired image-to-image translation using cycle-consistent adversarial networks. *In: PROCEEDINGS of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. P. 2223–2232. Citado na p. 49.