



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Isaac Leonardo Santos Sacramento

Redes Neurais Convolucionais para a Recuperação das Altas Frequências em Modelos de Impedância Acústica Pós-inversão Sísmica

Florianópolis

2019

Isaac Leonardo Santos Sacramento

**Redes Neurais Convolucionais para a Recuperação das Altas Frequências
em Modelos de Impedância Acústica Pós-inversão Sísmica**

Tese submetida ao Programa de Pós-Graduação
em Ciência da Computação para a obtenção do
título de Doutor em Ciência da Computação.
Orientador: Prof. Dr. Mauro Roisenberg

Florianópolis

2019

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Sacramento, Isaac Leonardo Santos

Redes Neurais Convolucionais para a Recuperação das
Altas Frequências em Modelos de Impedância Acústica Pós
inversão Sísmica / Isaac Leonardo Santos Sacramento ;
orientador, Mauro Roisenberg, 2019.

89 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Ciência da Computação, Florianópolis, 2019.

Inclui referências.

1. Ciência da Computação. 2. Redes Neurais
Convolucionais. 3. Inversão Sísmica. 4. Recuperação de
Frequência. 5. Deblurring. I. Roisenberg, Mauro. II.
Universidade Federal de Santa Catarina. Programa de Pós
Graduação em Ciência da Computação. III. Título.

Isaac Leonardo Santos Sacramento
Redes Neurais Convolucionais para a Recuperação das Altas Frequências em Modelos de Impedância Acústica Pós-inversão Sísmica

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

Prof. Alexandre Gonçalves Silva, Dr.
Universidade Federal de Santa Catarina

Prof. Marivaldo dos Santos Nascimento, Dr.
Universidade Federal de Santa Catarina

Prof. Milton José Porsani, Dr.
Universidade Federal da Bahia

Prof. Ricardo Azambuja Silveira, Dr.
Universidade Federal de Santa Catarina

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

Prof. Dr. José Luís Almada Güntzel
Coordenador do Programa

Prof. Dr. Mauro Roisenberg
Orientador

Florianópolis, 09 de agosto de 2019.

Dedico este trabalho aos meus pais Maria e Jarivaldo, que sempre me apoiaram e me motivaram em todos os momentos, principalmente nos de incerteza. À minha amada Lena, que foi a minha fonte de esperança e energia nos momentos mais críticos do desenvolvimento deste trabalho. À minha grande incentivadora Celia Sacramento, pelo apoio de sempre e por me apresentar a beleza em atuar na Academia.

AGRADECIMENTOS

Agradeço ao Professor Mauro Roisenberg, meu orientador, pela oportunidade de realizar este trabalho; pelas discussões e ideias que tanto contribuíram para o desenvolvimento desta pesquisa; meu imenso respeito e admiração por sua sabedoria. Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pela bolsa de estudos CAPES/DS, ao CENPES/PETROBRAS pelo suporte financeiro e disponibilidade durante os projetos de pesquisa e desenvolvimento executados ao decorrer da minha formação. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior- Brasil (CAPES) - Código de Financiamento 001. Agradeço ainda aos meus colegas do Laboratório de Conexionismo e Ciências Cognitivas (L3C) pelo excelente ambiente de trabalho e aprendizado constante. Meu agradecimento especial a Rafael Luneli, por sua parceria e imensa contribuição na diagramação deste trabalho.

Um dia é preciso parar de sonhar e, de algum modo, partir.
Amyr Klink

RESUMO

Na indústria de óleo e gás, a Inversão Sísmica é uma etapa de grande relevância para a caracterização dos reservatórios, pois é o processo pelo qual se obtém os modelos de propriedades de rocha na subsuperfície. Um aspecto crítico nesta etapa é obter modelos petrofísicos nítidos. Por causa da perda das altas frequências e do aumento do ruído aleatório durante a aquisição, o dado sísmico utilizado na inversão apresenta baixa nitidez e, conseqüentemente, resulta em modelos de propriedade com nitidez restrita à faixa de frequência do dado sísmico utilizado. Os métodos mais recentes abordam esse problema através do pré-processamento do dado sísmico para gerar um dado em maior resolução para a inversão. Entretanto, esta abordagem costuma reproduzir o ruído aleatório, juntamente com sinal de alta frequência e frequentemente ignora a disponibilidade de dados amostrais de propriedades petrofísicas em alta resolução disponíveis para a inversão. Este trabalho, por outro lado, tira proveito desses dados por considerar que podem contribuir para obter modelos invertidos mais nítidos. Assim, propôs-se um modelo de Rede Neural Convolutiva (CNN), utilizado como método de pós-processamento da inversão sísmica, para adicionar conteúdo de alta frequência à impedância acústica invertida. O modelo implementa a técnica de processamento de imagem conhecida como *deblurring* cego e busca inferir os filtros convolucionais a partir da análise de pares de imagens borradas e nítidas. Os experimentos realizados mostraram a viabilidade do modelo em dois conjuntos de dados sintéticos. O cálculo das magnitudes de frequências das imagens, antes e após o processamento com a CNN, evidenciaram o aumento de até 95% do conteúdo de alta frequência da impedância acústica. A aplicação do método proposto aumentou a resolução vertical das imagens, corrigiu deformações em estruturas geológicas e tornou mais visíveis as camadas delgadas, essas, eventualmente perdidas durante a inversão sísmica. O cálculo da razão sinal-ruído e a análise estatística com teste *t* mostraram que o método proposto foi superior a outros métodos de *deblurring* observados na literatura.

Palavras-chave: Redes Neurais Convolutivas. Inversão Sísmica. Impedância Acústica. *Deblurring*. Recuperação de Frequência.

RESUMO ESTENDIDO

Introdução

Os problemas inversos possuem um papel de grande relevância na indústria de óleo e gás, pois são um meio de estimar as propriedades das camadas da subsuperfície. Essas estimativas, por sua vez, dão suporte à tomada de decisão no processo exploratório. Nesse contexto, a impedância acústica é uma propriedade de grande interesse na inversão sísmica, pois a partir dela é possível inferir outras propriedades como a permeabilidade das rochas nas camadas.

Entretanto, frequentemente, as imagens de impedância acústica obtidas na inversão sísmica apresentam um aspecto borrado, ou desfocado, nas transições entre as camadas. Essa limitação está relacionada, em grande parte, com a banda de frequência limitada do dado sísmico. Na literatura, esse problema costuma ser abordado por meio do pré-processamento do dado sísmico, ou por meio da geração de modelos intermediários da propriedade invertida, afim de agregar-lhes conteúdo adicional de alta frequência. Por outro lado, a recuperação de imagens nítidas a partir de imagens borradas é um problema já conhecido na área de processamento de imagens, e que costuma ser tratado com soluções baseadas em *deblurring*.

As abordagens mais recentes para realização de *deblurring* envolvem o emprego de técnicas de Inteligência Artificial, com destaque para as Redes Neurais Convolucionais (CNNs), que têm apresentado resultados motivadores em diferentes domínios de aplicação. Em parte, o sucesso dessas redes se relaciona com a disponibilidade de dados para treinamento e com os avanços no desenvolvimento de Unidades Gráficas de Processamento (GPU). Ambos os recursos permitiram às redes neurais convolucionais superarem o estado da arte em tarefas de classificação de vídeo e imagens, de reconhecimento de ações e fala, dentre outras áreas.

A partir daí, é razoável supor que essas soluções possam contribuir para a área de inversão sísmica, tornando as imagens invertidas mais nítidas. Por fim, a motivação para buscar nas CNNs a solução para a perda das altas frequências na inversão sísmica está na sua capacidade de “aprender” padrões em um conjunto de imagens e reconstruí-los em regiões em que a sua presença não é totalmente evidente.

Objetivos

O objetivo principal deste trabalho é criar e aplicar modelos de redes neurais convolucionais para aumentar a resolução de modelos de impedância acústica obtidos com a inversão sísmica. Especificamente, este trabalho busca:

- Analisar e apresentar o conjunto de dados, com conteúdo de alta frequência para o treinamento de CNNs no cenário de *deblurring* pós-inversão sísmica;
- Propor uma arquitetura de ConvNet para aumentar a nitidez de imagens de impedância acústica pós-inversão sísmica.
- Conceber um modelo de rede neural convolucional, segundo a arquitetura proposta, para aumentar a resolução de imagens de impedância acústica pós-inversão sísmica;
- Demonstrar a possibilidade de aumentar a resolução da impedância acústica com um modelo de CNNs;
- Observar e mostrar o espectro de frequência das imagens pós-processadas com o modelo de rede convolucional;

- Pesquisar e demonstrar os impactos da aplicação das CNNs nas resoluções vertical e horizontal da impedância acústica invertida;
- Averiguar e evidenciar a viabilidade na aplicação do modelo de CNNs em contextos de escassez de dados.

Metodologia

A metodologia adotada neste trabalho consiste na construção de modelos de CNNs para recuperar o conteúdo de alta frequência da impedância acústica, perdido durante a inversão sísmica. As redes são treinadas em dois conjuntos de dados sintéticos, amplamente utilizados na literatura, por meio de aprendizagem supervisionada.

O primeiro conjunto de treinamento é composto por imagens nítidas, em formatos de cunhas, que representam uma mudança abrupta de litologias com diferentes velocidades de propagação da onda acústica. O aspecto borrado nessas imagens é induzido por meio da aplicação de filtros Gaussianos que removem as altas e médias frequências das imagens, de modo a suavizar a transição entre as litologias.

Na segunda estratégia, são utilizadas imagens nítidas de impedância acústica do reservatório Stanford VI. A partir dessas imagens é gerado um conjunto de sísmicas sintéticas, às quais é adicionado um ruído, igualmente Gaussiano. Nesse cenário, a obtenção das imagens de impedância acústica de baixa nitidez ocorre por meio da inversão sísmica por *Maximum a Posteriori* (MAP). Para aplicar esse processo, um modelo baixa frequência é calculado por filtragem Gaussiana e uma *wavelet* Ricker é estimada.

As imagens nítidas e borradas dos conjuntos de dados (cunhas e Stanford VI) foram utilizadas no treinamento de dois modelos de CNN. O primeiro modelo, treinado com as imagens de cunha, é composto por duas camadas que realizam convoluções bidimensionais. As camadas convolucionais são seguidas por camadas de ativação não linear do tipo *Rectified Linear Unit* (ReLU) e pela operação de máximo *pooling*. São adicionadas ainda, camadas totalmente conectadas, ativadas com a função Tangente Hiperbólica, a fim de prever os valores normalizados de impedância acústica.

Por sua vez, o segundo modelo adota uma abordagem baseada em convoluções unidimensionais. A arquitetura desse modelo contém uma camada convolucional padrão e uma camada de convolução localmente conectada, as quais são seguidas por ativação ReLU e máximo *pooling*. O modelo contém ainda, uma camada totalmente conectada com ativação linear. Após a fase de treinamento, cada uma das redes foi aplicada a um conjunto adicional de imagens. Essas, por sua vez, não apresetadas aos modelos no conjunto de aprendizagem.

Resultados e Discussão

Os resultados dos experimentos indicaram que é possível utilizar modelos de CNN para adicionar elementos de alta frequência aos modelos de impedância acústica, com potencial de aplicação para a inversão de outras propriedades, como a porosidade.

O modelo bidimensional apresentou resultados motivadores, na medida em que viabilizou a recuperação de elementos como bordas e contornos das cunhas. Entretanto, foi pouco eficaz na aplicação aos dados do reservatório Stanford VI, culminando na adição de ruído e baixa similaridade com as imagens de referência.

A abordagem unidimensional se mostrou mais viável, pois, além de aumentar a nitidez das imagens, corrigiu algumas deformações geradas durante o processo de inversão sísmica do conjunto de dados Stanford VI. Os resultados obtidos com esse modelo são de grande relevância, pois o espectro adicional de frequência observado nas imagens recuperadas pela rede, está associado à inserção de sinal de alta frequência, ao invés de ruído.

Como critério de avaliação, adotou-se o Pico de Razão Sinal-Ruído (PSNR) e a aplicação do teste estatístico t . Por meio do teste de hipóteses, constatou-se ainda a superioridade do modelo unidimensional de CNN em comparação com trabalhos observados na literatura.

Considerações Finais

As principais contribuições deste trabalho incluem:

- Especificação de um *workflow* para o pós-processamento da inversão sísmica.
- Concepção de um *benchmark* para o treinamento e teste de modelos de ConvNet aplicados na inversão sísmica.
- Concepção de um modelo de ConvNet para realizar *deblurring* em imagens de impedância acústica invertida.
- Aplicação do modelo para incorporar elementos adicionais de alta frequência na impedância acústica invertida.
- Um estudo de caso aplicando o *workflow* nos dados Stanford VI.

Palavras-chave: Redes Neurais Convolucionais. Inversão Sísmica. Impedância Acústica. Deblurring. Recuperação de Frequência.

ABSTRACT

In the oil and gas industry, Seismic Inversion is a very important step for reservoir characterization, as it is the process by which subsurface rock property models are obtained. A critical aspect at this stage is to obtain clear petrophysical models. Due to the loss of high frequencies and the increase of random noise during acquisition, the seismic data used in inversion presents low sharpness and, consequently, results in property models with sharpness restricted to the frequency range of the seismic data used. Newer methods address this problem by pre-processing seismic data to generate higher resolution data for inversion. However, this approach often reproduces random noise along with high frequency signal and often ignores the availability of high resolution petrophysical sample data available for inversion. This work, on the other hand, takes advantage of this data as it can contribute to clearer inverted models. Thus, a Convolutional Neural Network (CNN) model was proposed, used as a post processing method for seismic inversion, to add high frequency content to inverted acoustic impedance. The model implements the image processing technique known as blind deblurring and seeks to infer convolutional filters by analyzing pairs of blurred and sharp images. The experiments performed showed the viability of the model in two synthetic data sets. The calculation of the frequency magnitudes of the images before and after CNN processing showed an increase of up to 95 % of the high frequency content of the acoustic impedance. The application of the proposed method increased the vertical resolution of the images, corrected deformations in geological structures and made the thin layers more visible, eventually lost during seismic inversion. The signal-to-noise ratio calculation and statistical analysis with test t showed that the proposed method was superior to other deblurring methods observed in the literature.

Keywords: Convolutional Neural Networks. Seismic Inversion. Acoustic Impedance. Frequency Recovering. Deblurring.

LISTA DE ILUSTRAÇÕES

Figura 1 – Ilustração de lançamento de um fragmento de rocha em um poço. Fonte: o autor.	25
Figura 2 – Exemplo de convolução entre uma <i>wavelet</i> , uma série de refletividade e o traço sísmico. Fonte: o autor.	27
Figura 3 – Um evento sísmico acontece no instante $t = 0$ em um local (X, Y) desconhecido. As ondas sísmicas geradas por este evento são registradas em estações sísmicas de coordenadas cartesianas $\{(x_n, y_n)\}_{n=1}^N$ nos instantes $\{d_n\}_{n=1}^N$. O problema inverso para este sistema consiste em determinar o epicentro do evento a partir do tempo de propagação da onda. Fonte: o autor.	34
Figura 4 – Método de aquisição por sísmica de reflexão. Fonte: GSIPL (2017), adaptado pelo autor.	35
Figura 5 – Exemplo de <i>wavelet</i> Ricker (refletividade (r) em função do tempo (τ)). Modelo frequentemente utilizado como “chute” inicial durante o processo de extração da <i>wavelet</i> a partir de dados de poços. Fonte: o autor.	37
Figura 6 – Arquitetura típica de uma rede neural convolucional. Fonte: Géron (2017), adaptado pelo autor.	39
Figura 7 – Exemplo de convolução 1D. Fonte: o autor.	40
Figura 8 – Exemplo de convolução 2D em que cada valor do mapa de ativação é o resultado da convolução entre o filtro e a região da imagem que corresponde às suas dimensões. Fonte: Goodfellow, Bengio e Courville (2016) (2019). Adaptado pelo autor.	41
Figura 9 – Camadas de uma CNN. Fonte: Géron (2017), adaptador pelo autor.	42
Figura 10 – Não-linearidade da função <i>sigmoid</i> aplicada na camada de ativação dos modelos iniciais de CNNs. Fonte: o autor.	43
Figura 11 – Não-linearidade da função ReLU, cuja aplicação aumentou a performance das CNNs em relação ao uso da função <i>sigmoid</i> . Fonte: o autor.	44
Figura 12 – Operação de <i>pooling</i> máximo com vizinhança de tamanho 3. Nessa operação, seleciona-se o máximo valor de ativação da etapa de detecção. Fonte: Goodfellow, Bengio e Courville (2016).	45
Figura 13 – Fluxograma que combina um modelo de CNN como método de pós-processamento da inversão sísmica. Fonte: o autor.	53
Figura 14 – Comparação entre o (A) modelo de referência e (B) resultado da inversão sísmica. É possível notar o a perda de definição na região mais fina da estrutura obtida com a inversão. Fonte: Adaptado de Sancevero et al. (2005).	54
Figura 15 – Arquitetura de rede para recuperação bidimensional dos elementos de alta frequência em impedância acústica pós-inversão. Fonte: o autor.	56
Figura 16 – Arquitetura de rede para recuperação unidimensional dos elementos de alta frequência em impedância acústica pós-inversão. Fonte: o autor.	57

Figura 17 – Geração do modelo de impedância acústica. Cunha com valores de referência para densidade e velocidade compressional. Fonte: o autor.	60
Figura 18 – Modelo de impedância acústica borrada. Fonte: o autor.	60
Figura 19 – Exemplos de aplicação da rede convolucional para recuperar a alta frequência em imagens que apresentam impedância acústica com valores normalizados e cunhas posicionadas em 0°, 90°, 180° e 270°: Caso 1. Fonte: o autor.	62
Figura 20 – Exemplos de aplicação da rede convolucional para recuperar a alta frequência em imagens impedância acústica com valores normalizados entre 0,3 e 0,7 e cunhas posicionadas em 0°, 90°, 180° e 270°: Caso 2. Fonte: o autor. .	65
Figura 21 – Recuperação de frequência em cunhas posicionadas em 0°, 90°, 180° e 270° e impedância acústica borrada em diferentes frequências de corte: Caso 3. Fonte: o autor.	67
Figura 22 – Exemplos de aplicação da rede convolucional para recuperar a alta: Formas e ângulos aleatórios. Fonte: o autor.	69
Figura 23 – Canais meandantes de baixa sinuosidade compostos por quatro fácies: várzea (azul escuro), depósitos internos (azul claro), canais (amarelo) e limites (vermelho). (A) Estratigrafia e (B) cubo cartesiano. Fonte: Castro, Caers e Mukerji (2005).	70
Figura 24 – Canais meandantes altamente sinuosos compostos por quatro fácies: planície de inundação (azul escuro), depósitos internos (azul claro), canais (amarelo) e limites (vermelho). (A) Estratigrafia e (B) cubo cartesiano. Fonte: Castro, Caers e Mukerji (2005) (2005).	71
Figura 25 – Depósitos de planície deltaicos compostos por duas fácies: planície de inundação (azul escuro) e canais distributários (amarelo). (A) Estratigrafia e (B) cubo cartesiano. Fonte: Castro, Caers e Mukerji (2005).	71
Figura 26 – Modelo de impedância acústica Stanford VI Reservoir. Fonte: Castro, Caers e Mukerji (2005).	72
Figura 27 – Erros para o conjunto de treinamento e teste em cada época do treinamento do modelo. Fonte: o autor.	72
Figura 28 – Resultado da recuperação de frequência obtidos para um conjunto de teste. Planície de inundação e intersecções entre canais são evidenciados. Da esquerda para direita: imagem de referência da impedância acústica, resultado da CNN e impedância invertida. Fonte: o autor.	73
Figura 29 – Resultado de recuperação de frequência para um conjunto de teste. As setas indicam planícies de inundação e intersecção entre canais. Da esquerda para direita: imagem de referência da impedância acústica, resultado da CNN e impedância invertida. Fonte: o autor.	74

- Figura 30 – (A) comparação entre os espectros de frequência das imagens de impedância acústica real, a imagem da inversão MAP e as imagens de saída da CNN. (B) percentual de recuperação para cada magnitude de frequência. Fonte: o autor. 75
- Figura 31 – *Deblurring* cego. (Imagem Real) - imagens consideradas a realidade. (Inversão MAP) - imagens em baixa resolução obtidas com método de inversão MAP. (PAN et al., 2014b) - método proposto por Pan et al. (2014b). (TOFIGHI et al., 2016) método proposto por Tofighi et al. (2016). (CNN) - imagens recuperadas com a CNN proposta neste trabalho. Fonte: o autor. . . 87
- Figura 32 – *Deblurring* cego. (Imagem Real) - imagens consideradas a realidade. (Inversão MAP) - imagens em baixa resolução obtidas com método de inversão MAP. (PAN et al., 2014b) - método proposto por Pan et al. (2014b). (TOFIGHI et al., 2016) método proposto por Tofighi et al. (2016). (CNN) - imagens recuperadas com a CNN proposta neste trabalho. Fonte: o autor. . . 88

SUMÁRIO

1	INTRODUÇÃO	25
1.1	MOTIVAÇÃO E JUSTIFICATIVA	26
1.2	HIPÓTESE	30
1.3	OBJETIVO GERAL	30
1.3.1	Objetivos Específicos	30
1.4	ESTRUTURAÇÃO DO TEXTO	31
2	FUNDAMENTAÇÃO TEÓRICA	33
2.1	ASPECTOS DA INVERSÃO SÍSMICA	33
2.1.1	Aquisição do Dado Sísmico	35
2.1.2	A Estimativa da <i>Wavelet</i>	36
2.2	INVERSÃO SÍSMICA POR <i>MAXIMUM A POSTERIORI</i>	37
2.3	ASPECTOS DE REDES NEURAIS CONVOLUCIONAIS (CNNs)	38
2.3.1	Camada de Convolução	39
2.3.2	Propriedades das Camadas Convolucionais	42
2.3.3	Camada Localmente Conectada	43
2.3.4	Funções de Ativação	43
2.3.5	Camada de Pooling	44
2.4	DEBLURRING	45
3	TRABALHOS CORRELATOS	47
3.1	PLANO DE REVISÃO	47
3.2	BD BASEADO EM MÉTODOS DISCRIMINATIVOS	48
3.3	BD BASEADO EM APRENDIZAGEM	48
3.4	MÉTODOS DE AUMENTO DA RESOLUÇÃO NA INVERSÃO SÍSMICA	50
4	PROPOSTA PARA A RECUPERAÇÃO DAS ALTAS FREQUÊNCIAS DA IMPEDÂNCIA ACÚSTICA PÓS-INVERSÃO	53
4.1	ALTERNATIVAS PARA A ABORDAGEM DO PROBLEMA	53
4.1.1	O problema das estruturas acunhadas	54
<i>4.1.1.1</i>	<i>Arquitetura da CNN</i>	<i>55</i>
4.1.2	O problema das terminações das estruturas de canais	55
<i>4.1.2.1</i>	<i>Arquitetura da CNN</i>	<i>56</i>
4.2	FERRAMENTAS DE IMPLEMENTAÇÃO	57
5	EXPERIMENTOS E DISCUSSÕES	59
5.1	ABORDAGEM BIDIMENSIONAL	59
5.1.1	Dados de Estruturas Acunhadas	59

5.1.2	Treinamento do modelo bidimensional	60
5.1.3	Experimento I: Cunhas Rotacionadas 90 Graus	61
5.1.4	Experimento II: Cunhas com Formas e Ângulos de Rotação Aleatórios	68
5.2	ABORDAGEM UNIDIMENSIONAL	68
5.2.1	Dados de Reservatório: Stanford VI	70
5.2.2	Treinamento do modelo unidimensional	71
5.3	VALIDAÇÃO DOS RESULTADOS	75
5.4	VERIFICAÇÃO ESTATÍSTICA	76
5.5	CONSIDERAÇÕES FINAIS	78
6	CONCLUSÕES	79
6.1	CONTRIBUIÇÕES	79
6.2	PERSPECTIVAS FUTURAS	79
6.3	PUBLICAÇÕES GERADAS	80
	REFERÊNCIAS	81
	ANEXO A – IMAGENS COMPARATIVAS	87

1 INTRODUÇÃO

As teorias da Física permitem realizar previsões. Ou seja, com base em uma descrição completa de um sistema físico, é possível realizar previsões sobre alguma medida. Este procedimento é conhecido como problema direto (*forward problem*). Intuitivamente, é possível supor que o problema inverso (*inverse problem*) faz um caminho contrário, e utiliza os resultados reais de alguma medida para inferir os valores de parâmetros de um determinado sistema (TARANTOLA, 2005).

Para entender o problema inverso é conveniente explicar, antes, o problema direto. Considere o exemplo ilustrado na Figura 1. Suponha o lançamento de um fragmento de rocha em um poço de água e que, após determinado tempo, repercute-se um som. Assim, espera-se que haja uma relação entre a profundidade do poço e o tempo até ouvir o som do impacto da rocha no fundo do poço. Considere g a aceleração da gravidade e v_s a velocidade de propagação do som no meio onde o experimento é realizado. Da física, ocorre a relação causa-efeito dada por:

$$T = \sqrt{\frac{2H}{g}} + \frac{H}{v_s} \quad (1.1)$$

na qual a profundidade H é a causa e o tempo T é o efeito. Nesse caso, a solução do problema direto consiste em atribuir valores para H , conforme a Equação 1.1, de modo a obter o tempo T até a percepção do som do impacto no fundo do poço. Contudo, o problema inverso é uma abordagem mais difícil, pois se deseja saber a profundidade H , dada apenas a cronometragem do tempo T .



Figura 1 – Ilustração de lançamento de um fragmento de rocha em um poço. Fonte: o autor.

No exemplo citado, ambos os problemas (direto e inverso) possuem solução. Entretanto, a maioria dos problemas inversos recai sobre duas características que tornam sua solução

não-trivial. Primeiro, a não-unicidade de solução (problema não-determinístico), na qual o mesmo conjunto de medidas observáveis, pode resultar de mais de uma configuração de parâmetros. Em analogia ao exemplo citado, seria como obter diferentes alturas H para o mesmo tempo de queda T da rocha. Segundo, a natureza mal-posta do problema inverso, com a qual uma pequena mudança arbitrária nos valores observados, pode causar uma variação grande na solução. Novamente, sob a perspectiva do exemplo do poço, isso significa obter uma grande variação na profundidade, a partir de uma pequena variação no valor do tempo de queda.

A solução de problemas inversos desempenha um papel relevante em diferentes áreas do conhecimento, como Matemática, Medicina, Física e Geofísica. Em geofísica, a solução de problemas inversos ocorre, com frequência, no processo de caracterização de reservatórios, com o objetivo de obter um modelo de propriedades petrofísicas, em 3-D e alta resolução, coerente geologicamente com os dados disponíveis (DEUTSCH, 2002). Para alcançar esse objetivo é essencial combinar, por meio de um algoritmo de inversão, conhecimento e dados sobre o campo em estudo (FIGUEIREDO et al., 2018). Nesse sentido, os métodos sísmicos são o meio mais importante para se obter as descrições de tais propriedades (SEN, 2006a).

De acordo com Sen (2006a), a aplicação dos métodos sísmicos envolve estimar as camadas da subsuperfície a partir do eco de ondas sonoras que são propagadas ao longo da subsuperfície. Por sua vez, o conjunto de ecos registrados a partir da superfície caracteriza o dado sísmico e, portanto, os algoritmos de inversão que utilizam o dado sísmico são chamados de inversão sísmica.

No contexto da inversão sísmica, o modelo convolucional é a representação mais básica e mais utilizada para o dado sísmico (RUSSELL, 1988a). A Figura 2 ilustra o modelo convolucional, esse, define um traço sísmico como a operação de convolução da refletividade da subsuperfície (i.e., a diferença da propriedade impedância acústica entre os tipos de rocha) com uma função fonte (wavelet). Na figura é possível notar que a *wavelet* funciona como uma função que modula os picos de refletividade. O conjunto de traços, portanto, compõe o dado sísmico frequentemente utilizado na inversão sísmica.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

De acordo com Sancevero, Remacre e Portugal (2006), o uso de dados sísmicos pode conduzir a erros de estimativas em relação às propriedades do reservatório, pois tais dados permitem apenas um entendimento parcial do campo em estudo. Essa limitação se deve, principalmente, à atenuação sofrida pela onda acústica ao longo da subsuperfície e ao aumento de ruído durante a aquisição, tornando-se, assim, uma barreira importante para se obter imagens de impedância acústica de alta resolução durante a inversão sísmica (XIAOYU et al., 2012). Esse processo de atenuação causa, ainda, um impacto indesejado na *wavelet* estimada para a inversão, cujo espectro de frequência se torna limitado. Embora seja possível adicionar conteúdo de baixa frequência ao espectro da impedância acústica durante a inversão, sua banda permanece limitada para as altas frequências (ZHANG et al., 2012). Como consequência, as

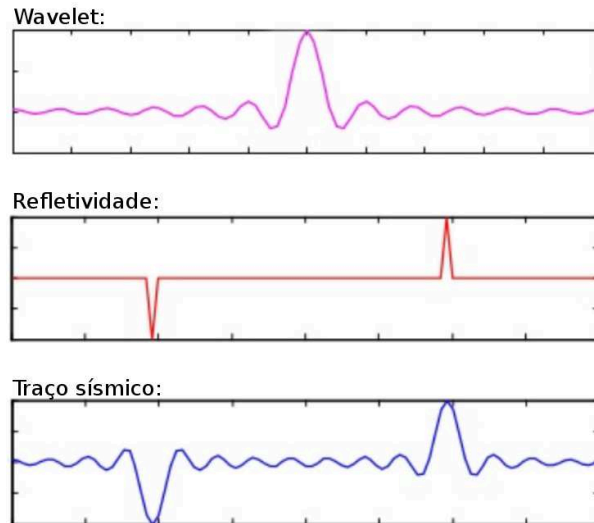


Figura 2 – Exemplo de convolução entre uma *wavelet*, uma série de refletividade e o traço sísmico. Fonte: o autor.

estruturas geológicas delgadas ganham pouco destaque durante a inversão sísmica e pode implicar em subestimativa dos volumes do reservatório e levar a perdas financeiras (ZHANG et al., 2012; FARIAS; FREITAS; TYGEL, 2008). Assim, a geração de modelos de impedância acústica de alta resolução, e com conteúdo adicional de alta frequência, torna-se um desafio com implicações relevantes no processo exploratório.

Farias, Freitas e Tygel (2008) propõem melhorar a nitidez do dado sísmico com o aumento da frequência crítica (frequência a partir da qual o sinal se confunde com o ruído) utilizando uma combinação das técnicas de *Common Reflection Surface* (CRS) com o Balançamento Espectral (*spectral whitening*) para a recuperação das altas frequências. Apesar de os resultados encontrados terem sido encorajadores, a técnica é fortemente dependente da parametrização adequada e da disponibilidade de uma grande quantidade de traços para serem empilhados pelo método CRS.

Outra abordagem para contornar o problema da “baixa resolução” na inversão sísmica é descrever a impedância acústica por meio de uma estrutura de blocos, o que implica em uma transição imediata entre as camadas do modelo. Com isso, são agregados elementos de alta frequência à impedância acústica, sem necessariamente dispor do dado sísmico de alta resolução. Embora esse método esteja presente no algoritmo de inversão *General Linear Inversion* (GLI), sua aplicação falha na definição, por exemplo, de corpos geológicos em formatos acunhados (COOKE et al., 2010). Segundo Cooke et al. (2010), a não-unicidade da solução inversa representa uma limitação adicional para essa abordagem. No caso de reservatórios mais finos que o intervalo de amostragem da *wavelet*, é possível estabelecer inúmeras combinações de reservatórios e impedâncias, dada a mesma amplitude sísmica. Adicionalmente, Yuan et al. (2015) reforçam sobre as limitações na suposição do modelo bloqueado ao mostrarem que se trata de uma hipótese frequentemente inválida, cujas soluções inversas ignoram as frequências mais altas.

Alternativamente, nos casos em que há disponibilidade de perfis de poços com conteúdo fora da banda de frequência sísmica, é possível gerar modelos intermediários de pseudo impedância acústica com elementos adicionais de baixa e alta frequência (JUN; BEI, 2010; WANG et al., 2010). Enquanto o conteúdo de baixa frequência pode ser obtido a partir de curvas acústicas, as altas frequências podem ser incorporadas ao modelo a partir de dados de curvas de potencial espontâneo, pois essas podem refletir condições reais das camadas (WANG et al., 2010). Ao final, os modelos de pseudo impedância com conteúdo adicional de frequência podem ser utilizados no processo de inversão sísmica para obter os modelos finais de impedância acústica.

A Teoria de Fourier permite representar um sinal temporal por meio da sua decomposição (a exemplo da *wavelet* extraída do dado sísmico) em uma combinação de senos ou cossenos em diferentes frequências e amplitudes. Partindo do princípio de que o sinal decomposto pode ser modificado no âmbito das suas frequências individuais, Chen e Wang (2018) utilizam operações de escalonamento para esticar o espectro de frequência e, por consequência, para comprimir a *wavelet*, de modo a aumentar o conteúdo de alta e baixa frequência. Em um nível mais fundamental, o escalonamento da *wavelet* se assemelha ao aumento de resolução da impedância acústica apresentado neste trabalho. Chen e Wang (2018) estimam, por meio dos mínimos quadrados, o filtro de transferência obtido através do escalonamento da *wavelet*. Com isso, a aplicação do filtro estimado sobre o dado sísmico aumenta a sua resolução e torna visível as camadas mais delgadas dos reservatórios de hidrocarbonetos do campo em estudo. Entretanto, apenas um padrão de filtro é estimado e nenhum conhecimento *a priori* é utilizado para distinguir entre sinal e ruído.

O processo de perda das altas frequências durante a inversão sísmica faz com que o resultado da maioria dos métodos de inversão apresente um aspecto de imagem borrada ou desfocada. Esse, por sua vez, é um problema já conhecido na área de processamento de imagens, e que costuma ser tratado com soluções baseadas em *deblurring*. A partir daí, pressupõe-se que essas soluções possam contribuir para a área de inversão sísmica, tornando as imagens invertidas mais nítidas.

Os métodos de *deblurring* mais recentes utilizam técnicas de *Deep Learning* para recuperar imagens de alta resolução a partir de imagens de baixa resolução. Goodfellow, Bengio e Courville (2016) definem *Deep Learning* como toda solução que permite a aprendizagem de computadores a partir da experiência e a compreensão do mundo em termos de hierarquia de conceitos. Ou seja, os computadores apreenderem conceitos complexos a partir de conceitos mais simples. Por exemplo, é possível treinar um computador para identificar um certo objeto em uma foto (conceito complexo), a partir da identificação de elementos fundamentais desse objeto, como bordas e contornos (conceitos simples).

Nos algoritmos de *Deep Learning*, o aprendizado por experiência (supervisionado) evita a interferência humana e dispensa a especificação formal do conhecimento que o computador necessita. Nesse contexto, as Redes Neurais Convolucionais (CNN) representam um método de grande destaque nos dias atuais. Em parte, o sucesso dessas redes se relaciona com

a disponibilidade de dados para treinamento (RUSSAKOVSKY et al., 2015) e aos avanços no desenvolvimento de Unidades Gráficas de Processamento (GPU) (BUDUMA, 2015). Ambos recursos permitem às redes neurais convolucionais superarem o estado da arte em tarefas de classificação de vídeo e imagens (KRIZHEVSKY; SUTSKEVER; HINTON, 2012; ABDELHAMID et al., 2014), o reconhecimento de ações e fala (FARFADE; SABERIAN; LI, 2015; JI et al., 2013), dentre outras áreas.

A motivação para buscar nas CNNs a solução para a perda das altas frequências na inversão sísmica, portanto, está na sua capacidade de “aprender” padrões em um conjunto de imagens e reconstruí-los em regiões em que a sua presença não é totalmente evidente. Esse é o processo pelo qual as CNNs têm apresentado resultados animadores na realização de *deblurring*.

Schuler et al. (2016) demonstram que é possível treinar uma CNN para realizar *deblurring* pela extração de características das imagens borradas, seguida da inferência dos filtros convolucionais e na aplicação destes filtros para estimar imagens em alta resolução. Posteriormente, o grupo *Google DeepMind* apresentou novos avanços na concepção das ferramentas para a implementação dos modelos de CNNs e concebeu novas estratégias de treinamento. O trabalho desse grupo se relaciona, principalmente, com a construção dos modelos condicionais conhecidos como ResNet (HE et al., 2016) e *Gated PixelNN* (OORD et al., 2016). Essas inovações se tornaram referências na concepção de novos modelos de CNN para aumentar a resolução em imagens, por exemplo, de faces humanas (DAHL; NOROUZI; SHLENS, 2017).

Embora as CNNs sejam um tema em forte evidência nos dias atuais, sua adoção como solução no campo da caracterização de reservatórios ainda é incipiente. Recentemente, essas redes apresentaram resultados inspiradores no cálculo de litofácies (LIU et al., 2017), no processamento do dado sísmico para a interpretação de estruturas da subsuperfície (ALREGIB et al., 2018) e no mapeamento da resistividade elétrica para o delineamento de sal (OH et al., 2019). Porém, observa-se que há um campo fértil para a investigação relacionado à geração de modelos de alta resolução na inversão sísmica. Portanto, este trabalho pretende preencher parte dessa lacuna e servir de suporte para superar possíveis barreiras relacionadas a este tema.

A abordagem desenvolvida neste trabalho se dá pela incorporação de um modelo CNN como método de pós-processamento da inversão sísmica. Nesse sentido, a concepção do modelo pode ser sumarizada em duas etapas: treinamento e aplicação. Para o treinamento do modelo, são utilizadas imagens de impedância acústica borradas como dados de entrada, as quais são obtidas por meio de um método de inversão sísmica. Uma vez que a aprendizagem modelo é supervisionada, esta metodologia assume a ocorrência das imagens de impedância acústica nítidas. Nessa fase, a CNN deve inferir um conjunto de filtros a partir da análise dos padrões de alta frequência existentes entre os exemplos de impedância acústica nítidas e borradas. Por fim, na fase de aplicação, os filtros inferidos são aplicados a um conjunto de imagens de impedância borrada, a fim de inserir-lhes elementos de alta frequência e tornar imagens borradas mais nítidas.

1.2 HIPÓTESE

A geração de modelos de impedância acústica em alta resolução durante a inversão sísmica é um problema relevante na caracterização de reservatórios. As abordagens existentes para lidar com esse problema são insuficientes e, na maior parte dos casos, estão focadas no aumento da resolução do dado sísmico utilizado na inversão. Assim, pretende-se, ao longo deste trabalho, responder à seguinte questão de pesquisa: é possível que a aplicação dos métodos de *Deep Learning* seja uma estratégia viável para a recuperação das altas frequências perdidas na inversão sísmica?

1.3 OBJETIVO GERAL

Para verificar a hipótese apresentada, este trabalho de pesquisa busca criar e aplicar modelos de redes neurais convolucionais para aumentar a resolução de modelos de impedância acústica obtidos com a inversão sísmica.

1.3.1 Objetivos Específicos

Especificamente, este trabalho busca:

- Analisar e apresentar o conjunto de dados, com conteúdo de alta frequência para o treinamento de CNNs no cenário de *deblurring* pós-inversão sísmica;
- Propor uma arquitetura de ConvNet para aumentar a nitidez de imagens de impedância acústica pós-inversão sísmica.
- Conceber um modelo de rede neural convolucional, segundo a arquitetura proposta, para aumentar a resolução de imagens de impedância acústica pós-inversão sísmica;
- Demonstrar a possibilidade de aumentar a resolução da impedância acústica com um modelo de CNNs;
- Observar e mostrar o espectro de frequência das imagens pós-processadas com o modelo de rede convolucional;
- Pesquisar e demonstrar os impactos da aplicação da CNNs nas resoluções vertical e horizontal da impedância acústica invertida;
- Averiguar e evidenciar a viabilidade na aplicação do modelo de CNNs em contextos de escassez de dados.

1.4 ESTRUTURAÇÃO DO TEXTO

Este documento está organizado da seguinte forma: Após a introdução, o Capítulo 2 apresenta a fundamentação teórica dos processos de inversão sísmica, os principais conceitos relacionados às redes convolucionais e à construção destes modelos de redes neurais. O Capítulo 3 apresenta o estado da arte relacionado às técnicas para a realização de *deblurring* e à obtenção de modelos de alta resolução no processo de inversão sísmica. O Capítulo 4 trata dos modelos de redes neurais convolucionais implementados durante o desenvolvimento deste trabalho. O Capítulo 5 apresenta os experimentos realizados com os modelos de redes convolucionais propostos. Por fim, o Capítulo 6 sumariza os resultados alcançados com este estudo e finaliza com as sugestões para a sua continuidade.

2 FUNDAMENTAÇÃO TEÓRICA

Para estimar os modelos de propriedades petrofísicas da subsuperfície a partir dos dados sísmicos, o processo de inversão sísmica compreende uma série de etapas, as quais serão apresentadas. Inicialmente, será introduzida a modelagem do problema inverso, seguida de uma breve visão do método de aquisição marinha do dado sísmico. Destaca-se ainda o processo de estimação da *wavelet* e o impacto que a restrição de frequência causa na impedância acústica estimada.

Em seguida, será descrita a inversão determinística por *Maximum a Posteriori* (MAP) desenvolvida por Figueiredo et al. (2014). Nos métodos de inversão determinística, as altas e baixas frequências são filtradas (COOKE et al., 2010), o que implica em obter a propriedade invertida com resolução vertical restrita à largura de banda limitada do dado sísmico (SANCEVERO et al., 2005).

Serão apresentados, ainda, os aspectos relacionados com as Redes Neurais Convolucionais. Nesse sentido, serão introduzidos, primeiramente, o funcionamento e as características das estruturas que compõem uma CNN. Em seguida, serão apresentadas as funções frequentemente usadas na ativação de características. Por fim, será descrito o problema de *deblurring*. Com essa fundamentação, busca-se o entendimento de como os elementos que compõem um modelo de CNN contribuem para o ganho qualitativo e quantitativo na resolução da impedância acústica.

2.1 ASPECTOS DA INVERSÃO SÍSMICA

Diferentes áreas do conhecimento aplicam a teoria da inversão com o intuito de inferir os valores de parâmetros relacionados aos processos físicos. Para alcançar tal objetivo, é comum construir modelos que combinam dados e conhecimentos *a priori*, por meio de relações teóricas entre esses e um conjunto de parâmetros desejados. Frequentemente, a construção de tais modelos envolve três passos básicos: a parametrização do sistema, a modelagem direta e a modelagem inversa (TARANTOLA, 2005).

Na etapa de parametrização, define-se o conjunto mínimo de elementos, cujos valores caracterizam o sistema em estudo. Isso significa que nessa etapa se estabelecem os elementos constitutivos do espaço referente aos dados $\mathbf{d} = (d_1, d_2, \dots, d_n)$ (parâmetros observáveis). Os mesmos são obtidos a partir da observação de experimentos físicos. Nessa fase são definidos, igualmente, os parâmetros do modelo $\mathbf{m} = (m_1, m_2, \dots, m_n)$ (parâmetros não-observáveis), que compõem os elementos passíveis de se quantificar durante a inversão. Assim, cada conjunto de valores para \mathbf{d} e \mathbf{m} representa, respectivamente, um ponto no espaço dos dados e no espaço do modelo. Esse, por sua vez, admite diferentes parametrizações devido à natureza mal posta dos problemas inversos (TARANTOLA, 2005).

Para ilustrar a etapa de parametrização, considere o exemplo no qual se deseja estimar as coordenadas do epicentro de um evento sísmico (por exemplo a explosão de uma bomba

atômica ou um terremoto), ilustrado na Figura 3. O evento sísmico ocorre no tempo $t = 0$ em um local desconhecido de coordenada (X, Y) sobre a superfície da Terra (considerada plana). As ondas sísmicas causadas pelo evento são registradas por um conjunto de N sensores localizados nas coordenadas Cartesianas $\{(x_n, y_n)\}_{n=1}^N$, de modo que $\mathbf{d}_n = d_n$ é o tempo entre a ocorrência do evento e a observação da onda no sensor n . Além disso, a onda sísmica se propaga em todas as direções com uma velocidade v . Nesse exemplo simplificado, os possíveis parâmetros do modelo a serem determinados a partir dos parâmetros observáveis $\{d_n\}_{n=1}^N$ são:

- as coordenadas (X, Y) do epicentro;
- as coordenadas de cada sensor (x_n, y_n) ;
- o instante de ocorrência do evento;
- e a velocidade v da onda.




Figura 3 – Um evento sísmico acontece no instante $t = 0$ em um local (X, Y) desconhecido. As ondas sísmicas geradas por este evento são registradas em estações sísmicas de coordenadas cartesianas $\{(x_n, y_n)\}_{n=1}^N$ nos instantes $\{d_n\}_{n=1}^N$. O problema inverso para este sistema consiste em determinar o epicentro do evento a partir do tempo de propagação da onda. Fonte: o autor.

Desse modo, o sistema físico pode ser modelado com $\mathbf{m} = (X, Y, t, v, x_1, y_1, \dots, x_n, y_n)$. Uma vez que as coordenadas dos sensores, o tempo de propagação da onda (considerado constante) e o instante de ocorrência do evento são conhecidos, os parâmetros do modelo a serem determinados se reduzem a $\mathbf{m} = (X, Y)$.

Por meio da modelagem direta, calcula-se os valores dos dados d correspondentes a uma certa configuração dos parâmetros do modelo m . A Equação 2.1 denota a modelagem direta por meio do operador direto $G(\cdot)$.

$$\mathbf{d} = G(\mathbf{m}). \quad (2.1)$$

Por sua vez, durante a modelagem inversa, são definidos os procedimentos experimentais com os quais, utilizando os elementos dos parâmetros dos dados (d), estima-se as quantidades físicas

dos parâmetros do modelo (m), segundo a relação da Equação 2.2.

$$\mathbf{m} = G^{-1}(d) \quad (2.2)$$

Em Geofísica, o espaço dos dados é composto, principalmente, pelo dado sísmico, pela *wavelet* (admitindo-se o modelo convolucional) e, possivelmente, por um modelo de baixa frequência. Por sua vez, o espaço do modelo admite diferentes propriedades, como demonstrado na inversão conjunta descrita por Figueiredo et al. (2017), Figueiredo et al. (2018). No entanto, no escopo desta pesquisa, a inversão sísmica busca estimar apenas a impedância acústica das camadas da subsuperfície.

2.1.1 Aquisição do Dado Sísmico

Na aquisição de dados sísmicos por reflexão, emite-se um pulso sísmico (*wavelet*) a partir de uma fonte artificial controlada, e se monitora a resposta em função do tempo. À medida que a onda se propaga e alcança superfícies de contato entre camadas de rocha, uma parte da energia reflete e outra parte se propaga para as camadas mais profundas da subsuperfície, como ilustrado na Figura 4. Os dispositivos hidrofones (ou geofones, para o caso da aquisição terrestre), posicionados na superfície, capturam as reflexões produzidas, ao passo que as refrações se propagam para as regiões mais profundas da subsuperfície até alcançarem uma nova superfície de contato.




Figura 4 – Método de aquisição por sísmica de reflexão. Fonte: GSIPL (2017), adaptado pelo autor.

Seguindo o modelo convolucional discretizado, dado pela Equação 2.3 (SEN, 2006a), cada traço sísmico d é representado pela convolução \otimes entre a *wavelet* s e os coeficientes de refletividade r , ao longo das N camadas da subsuperfícies. Admite-se, ainda, um ruído aleatório $e_d(t)$.

$$d(t) = s(\tau) \otimes \sum_{j=1}^N r(t - t_j) \delta(t - t_j) + e_d(t) \quad (2.3)$$

Por sua vez, o coeficiente de refletividade expressa a diferença de impedâncias acústicas entre dois meios nos quais a onda se propaga. A Equação 2.4 (SEN, 2006a) define o coeficiente de

refletividade, no qual $z(t)$ é a impedância acústica no tempo t .

$$r(t) = \frac{z(t + \delta t) - z(t)}{z(t + \delta t) + z(t)} \quad (2.4)$$

Por fim, a impedância acústica relaciona a densidade $\rho(t)$ da rocha e a velocidade $v(t)$ de propagação da onda acústica por meio da relação apresentada na Equação 2.5.

$$z(t) = \rho(t)v(t) \quad (2.5)$$

Conforme se observa no modelo convolucional, a capacidade de distinguir estruturas no dado sísmico depende fortemente da *wavelet*. Essa capacidade se relaciona à resolução horizontal e vertical do dado sísmico. Se, por um lado, aquela está ligada à distância em quem dois pontos de reflexão precisam estar separados para que se possa identificá-los como pontos distintos; por outro, a resolução vertical está diretamente ligada à frequência da *wavelet* (SEN, 2006a).

2.1.2 A Estimativa da *Wavelet*

A *wavelet* desempenha um papel importante no processamento do dado sísmico, pois quanto mais componentes de alta a frequência estiverem contidos no pulso, mais finos os detalhes observáveis na sísmica (SEN, 2006a). Consequentemente, será maior a resolução das imagens da propriedade física invertida. Portanto, a *wavelet* ideal é uma função delta, contendo o espectro completo de frequências, com a qual seria possível identificar os limites individuais de cada camada da subsuperfície. Entretanto, quando o pulso sísmico é emitido, o nível de energia varia com o tempo de modo que, quanto maior a profundidade, menor a resolução do dado sísmico. Ou seja, na prática, o formato da *wavelet* muda com o tempo (RUSSELL, 1988a; SEN, 2006a).

Apesar disso, frequentemente se assume que a *wavelet* é estacionária e de banda limitada (SEN, 2006a). Durante a inversão é necessário estimá-la por meio de um método de otimização, frequentemente com o uso do dado sísmico e de perfis de poços (dados coletados experimentalmente a partir de poços perfurados).

Com os modelos de velocidade compressional e valores de densidade nos poços, calcula-se a impedância acústica e, em seguida, a série “real” de refletividades, conforme a Equação 2.4 (SEN, 2006b). Na sequência, define-se uma *wavelet* padrão como modelo inicial. Frequentemente, se utiliza a *wavelet* do tipo Ricker (Figura 5), pois seu espectro de amplitude é capaz de representar a característica de atenuação sofrida pela onda sísmica (WANG, 2014).

A *wavelet* inicial será convolucionada com a refletividade calculada, resultando no traço sísmico sintético. Naturalmente, o traço sísmico sintético e o traço real serão diferentes, porém, é possível obter a solução ótima através da minimização da diferença entre o traço sísmico observado e o traço sintético calculado. Sen (2006a) descreve apropriadamente os possíveis algoritmos de otimização para a extração da *wavelet*.




Figura 5 – Exemplo de *wavelet* Ricker (refletividade (r) em função do tempo (τ)). Modelo frequentemente utilizado como “chute” inicial durante o processo de extração da *wavelet* a partir de dados de poços. Fonte: o autor.

2.2 INVERSÃO SÍSMICA POR *MAXIMUM A POSTERIORI*

A maioria dos problemas geofísicos apresenta características de não-linearidade do modelo direto. Na inversão sísmica a não-linearidade implica em uma função de custo com forma irregular, possivelmente com mínimos locais (RUSSELL, 1988b). Por outro lado, se o modelo direto for aproximadamente linear, a função de erro se tornará quadrática em relação às perturbações no espaço do mesmo. Assim, a maior parte da teoria de inversão é baseada em problemas de inversão linear e, em muitas aplicações, ela é adequada para representar a natureza do sistema (SEN, 2006c).

A abordagem clássica para escapar da problemática da não-linearidade do operador direto na inversão acústica, baseia-se em aproximar linearmente o pulso sísmico da impedância acústica. Para isso, o dado sísmico é discretizado para:

$$\mathbf{d} = \mathbf{S} \cdot \mathbf{r} + \mathbf{e}_a, \quad (2.6)$$

\mathbf{S} é um vetor convolucional construído utilizando uma *wavelet*, \mathbf{r} é o vetor de refletividades e \mathbf{e}_a é um ruído admitido. Em seguida, admite-se a equivalência entre a refletividade e o logaritmo natural da impedância acústica (Equação 2.7), uma vez que tal hipótese seja válida para valores de refletividade menores que 0,3 (BULAND; OMRE, 2003).

$$r(t) = \frac{1}{2} \frac{\partial}{\partial t} \ln(z(t)). \quad (2.7)$$

Por fim, adota-se um operador diferencial \mathbf{D} para tornar linear a relação entre o dado sísmico e o parâmetro do modelo (impedância acústica), por meio da Equação 2.8. Tem-se, portanto, o operador direto linearizado $\mathbf{G}=(1/2)\mathbf{SD}$ e o parâmetro do modelo $m = \ln(z)$.

$$\mathbf{d} = \mathbf{G}m + \mathbf{e}_a. \quad (2.8)$$

A abordagem probabilística é o caminho mais simples e genérico para tratar um problema inverso (TARANTOLA, 2005). Desse modo, os parâmetros da Equação 2.8 podem ser representados em termos de suas distribuições de probabilidade. Seguindo essa abordagem, o modelo de inversão proposto por Figueiredo et al. (2014) assume distribuições normais e multivariadas para representar a solução inversa, denotando-os como $\mathbf{N}(\mu, \Sigma)$. Assumindo que o

ruído \mathbf{e}_d respeita uma distribuição igualmente gaussiana, se define as distribuições *likelihood* para os dados sísmicos d , para a *wavelet* s e para os parâmetros m do modelo por meio das Equações 2.9, 2.10 e 2.11, respectivamente.

$$p(d|\mu_d, \Sigma_d) = N(\mu_d, \Sigma_d), \quad (2.9)$$

μ_d é o vetor contendo a sísmica sintética e Σ_d é a matriz de covariância do ruído da sísmica, definida conforme a confiabilidade que o especialista tem no dado sísmico ou no nível de ruído.

$$p(s|\mu_s, \Sigma_s) = N(\mu_s, \Sigma_s), \quad (2.10)$$

μ_s e Σ_s são, respectivamente, o valor esperado e a matriz de covariância da *wavelet* estimada (FIGUEIREDO et al., 2014).

$$p(m|\mu_m, \Sigma_m) = N(\mu_m, \Sigma_m). \quad (2.11)$$

O modelo incorpora informações *a priori* na representação da distribuição dos parâmetros do modelo (μ_m). Essas informações estão disponíveis eventualmente na forma de uma matriz de baixa frequência, gerada a partir da interpolação da impedância acústica calculada em dois ou mais poços. A matriz de covariância dos parâmetros do modelo (Σ_m) está relacionada à correlação espacial e, conseqüentemente, com a banda de frequência desejada no resultado da inversão (FIGUEIREDO et al., 2014).

A inversão por MAP ocorre para cada traço a partir das distribuições condicionais e do modelo convolucional apresentados anteriormente. Obtém-se a distribuição posterior para o parâmetro do modelo, por meio da solução exponencial, dada pela Equação 2.12.

$$p(m|d, s, \mu_m, \sigma_d^2, \sigma_m^2) = N(\mu_m, \Sigma_m). \quad (2.12)$$

Essa, possui média

$$\mu_{m|} = \mu_m + \Sigma_m \mathbf{G}^T (\mathbf{G} \Sigma_m \mathbf{G}^T + \Sigma_d)^{-1} (d - \mathbf{G} \mu_m), \quad (2.13)$$

e covariância

$$\Sigma_{m|} = \Sigma_m - \Sigma_m \mathbf{G}^T (\mathbf{G} \Sigma_m \mathbf{G}^T + \Sigma_d)^{-1} \mathbf{G} \Sigma_m. \quad (2.14)$$

Através das perturbações observadas na sísmica \mathbf{d} e na baixa frequência μ_m , tem-se a solução inversa por MAP, dada pela média (Equação 2.13) posterior, com variância $\Sigma_{m|}$ (Equação 2.14) (FIGUEIREDO et al., 2014)¹.

2.3 ASPECTOS DE REDES NEURAIAS CONVOLUCIONAIS (CNNs)

As CNNs são redes neurais artificiais de múltiplos estágios, especializadas no processamento de dados com topologia de grade (LECUN, 1989; GOODFELLOW; BENGIO;

¹ Os detalhes da dedução das distribuições posteriores da *wavelet* e dos parâmetros do modelo estão apropriadamente descritos e podem ser consultados em Figueiredo et al. (2014).

COURVILLE, 2016). A construção em múltiplos estágios conferem às CNNs a capacidade de extrair padrões e características espaciais existentes em um conjunto de dados. A Figura 6 mostra a estrutura básica de uma CNN.



Figura 6 – Arquitetura típica de uma rede neural convolucional. Fonte: Géron (2017), adaptado pelo autor.

A extração das características se dá por meio da operação de convolução entre os dados de entrada da rede e um conjunto de filtros, cujos valores são otimizados por um algoritmo de aprendizagem. Essa, portanto, é a principal característica que difere as CNNs das redes neurais tradicionais, cujas camadas intermediárias realizam a operação de multiplicação padrão de matrizes.

Cada estágio em uma CNN contém ainda uma camada de ativação não-linear, responsável pela identificação das características previamente extraídas na camada convolucional. Em seguida, as características identificadas são submetidas a uma camada de síntese estatística, conhecida como *pooling*. Com essa organização básica, cada estágio produz mapas de características que representam padrões específicos extraídos de diferentes regiões da entrada (LECUN; KAVUKCUOGLU; FARABET, 2010).

Frequentemente, adicionam-se camadas densas entre o último estágio e a camada de saída da rede. As camadas densas, também chamadas de camadas totalmente conectadas, são representadas por um conjunto de neurônios, os quais são conectados através de pesos a todos os neurônios da camada densa seguinte (densa/saída). Essas camadas adicionais desempenham uma função, similar às totalmente conectadas em uma rede neural tradicional do tipo *feed-forward*, pois realizam a combinação das saídas dos estágios, de modo a obter uma predição dos valores de saída da rede.

2.3.1 Camada de Convolução

Define-se a operação de convolução como a integral do produto de duas funções, após uma delas sofrer um certo deslocamento no tempo ou no espaço, conforme expressa a Equação 2.15.

$$s(t) = \int_{-\infty}^{\infty} x(a) \cdot w(t - a) da. \quad (2.15)$$

Computacionalmente, a integral da Equação 2.15 representa o somatório da região de sobreposição das funções x e w , à medida que se desloca w em relação a x . A Equação 2.16

ilustra a discretização da operação de convolução

$$s(t) = (x \otimes w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a). \tag{2.16}$$

No contexto das redes convolucionais, x se refere ao conjunto de imagens de entrada e w é um conjunto de filtros. As imagens de entrada são uma sequência de dados, enquanto os filtros são uma sequência de parâmetros a serem otimizados pelo algoritmo de aprendizagem.

Para exemplificar, considere as representações matriciais unidimensionais de $x = [1\ 2\ 3\ 4]$ e $w = [1\ 2]$. Imagine que ambas as matrizes são dispostas como ilustrado na Figura 7 e que a matriz w será deslocada em relação a x . Desse modo, a cada deslocamento, multiplica-se os elementos de x que estão alinhados verticalmente com os elementos de w . Em seguida, todo produto vertical obtido do alinhamento entre x e w é somado para gerar um resultado final.




Figura 7 – Exemplo de convolução 1D. Fonte: o autor.

A primeira interação da convolução é calculada a partir da sobreposição do primeiro elemento de x e de w . Uma vez que essa sobreposição é apenas parcial, pode-se adicionar um novo elemento de valor 0 na posição mais à esquerda do vetor x . Com isso, o segundo elemento de w passa a ter um elemento equivalente em x para ser multiplicado. Assim, é possível calcular o primeiro elemento da convolução $s_{x,w}(1)$.

Para o cálculo da segunda interação da convolução, desloca-se $s_{x,w}(2)$, w uma posição à direita e, nesse ponto, se observa a sobreposição total entre os vetores. Calcula-se os produtos dos elementos alinhados verticalmente e, em seguida, soma-se os resultados. As iterações seguintes seguem estritamente os passos da interação anterior, enquanto houver sobreposição total entre x e w (i.e. $s_{x,w}(2)$, $s_{x,w}(3)$ e $s_{x,w}(3)$).

O cálculo da interação $s_{x,w}(5)$ requer a aplicação da mesma medida adotada na primeira interação, dessa vez com a adição de um elemento de valor 0 na posição mais à direita de x . Com isso, o primeiro elemento de w será multiplicado por 0. Por fim, a operação acaba quando não há sobreposição entre elementos de x e de w e resulta no vetor $s_{x,w} = x * w = [1\ 4\ 7\ 10\ 8]$.

Frequentemente, os dados e os filtros em uma CNN são matrizes multidimensionais, de modo que a convolução ocorre em mais de uma dimensão ao mesmo tempo. Assim, considerando uma imagem (\mathbf{X}) em duas dimensões como entrada e um filtro convolucional (\mathbf{W}) também em duas dimensões, a operação de convolução assume a representação discretizada da Equação 2.17

$$S(i, j) = (\mathbf{X} \otimes \mathbf{W})(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \mathbf{X}(i-m, j-n) \mathbf{W}(m, n), \quad (2.17)$$

na qual $M = A + B - 1$ e $N = C + B - 1$, sendo A e B as dimensões da imagem \mathbf{X} , e C e D as dimensões do filtro \mathbf{W}

A Figura 8 ilustra a operação de convolução 2D de uma maneira simplificada. Neste exemplo, a primeira iteração ocorre com a sobreposição completa entre X e W . Além disso, os filtros são deslocados uma posição horizontalmente e verticalmente nas iterações seguintes, de modo que as convoluções são sobrepostas. Entretanto, esse aspecto da convolução é parametrizável na construção de um modelo de CNN. As setas ilustram a forma como cada convolução do filtro com uma região da imagem produz um valor de ativação no mapa de característica.

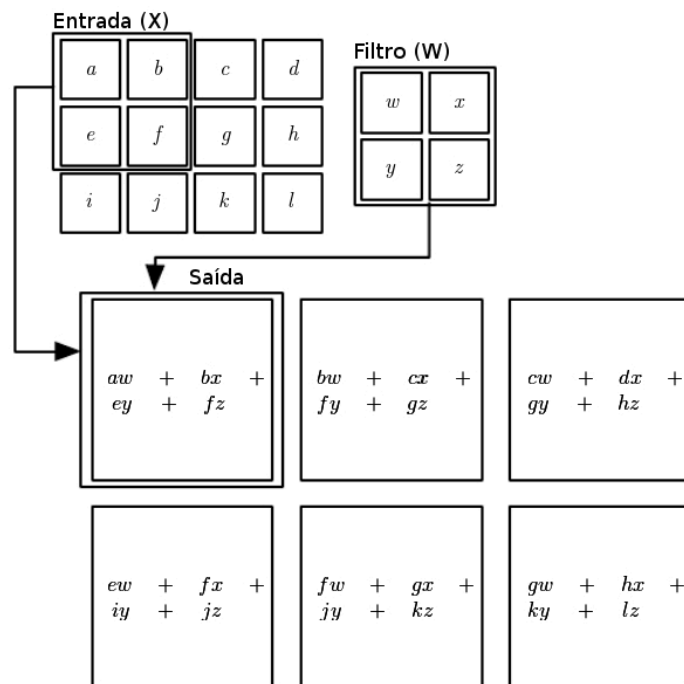


Figura 8 – Exemplo de convolução 2D em que cada valor do mapa de ativação é o resultado da convolução entre o filtro e a região da imagem que corresponde às suas dimensões. Fonte: Goodfellow, Bengio e Courville (2016) (2019). Adaptado pelo autor.

A operação das camadas convolucionais permite que cada elemento dos filtros esteja conectado a um pequeno grupo de *pixels* da camada de entrada, como ilustrado na Figura 9. À medida que as imagens são processadas ao longo da rede, suas dimensões diminuem após a aplicação da *pooling*, tornando-as mais profundas em termos de características extraídas.

Com essa estrutura, a rede é capaz de apreender características de mais baixo nível na primeira camada e características de mais alto nível nas camadas seguintes (GÉRON, 2017).




Figura 9 – Camadas de uma CNN. Fonte: Géron (2017), adaptador pelo autor.

2.3.2 Propriedades das Camadas Convolucionais

A vantagem na utilização da operação de convolução consiste em três ideias, que são fundamentais para a implementação de um sistema de aprendizagem de máquina eficiente: (a) conectividades locais, (b) compartilhamento de pesos e (c) estrutura de dados em grade (GOODFELLOW; BENGIO; COURVILLE, 2016).

- (a) **Conectividades locais:** as redes neurais tradicionais utilizam a multiplicação entre matrizes no processamento entre os dados de entrada e os parâmetros em cada uma das suas camadas. Isso significa que todos os neurônios em uma rede tradicional interagem com todos os elementos da entrada da rede. Por outro lado, as camadas convolucionais permitem a identificação de correlações espaciais locais nas imagens de entrada.
- (b) **Compartilhamento de pesos:** faz com que a mesma convolução seja válida globalmente na imagem. Ou seja, o mesmo filtro é utilizado para identificar características em todas as partes do conjunto de entrada (LECUN; KAVUKCUOGLU; FARABET, 2010; GOODFELLOW; BENGIO; COURVILLE, 2016).
- (c) **Dados em grade:** o processamento em grade permite que a convolução gere mapas com a localização das características apreendidas nas imagens. Assim, se as características mudam de posição nas imagens de entrada, sua representação será igualmente modificada na saída da rede.

2.3.3 Camada Localmente Conectada

As camadas convolucionais localmente conectadas são um caso particular das camadas convolucionais padrões. A diferença está no fato de que, em uma camada localmente conectada, cada filtro é aplicado em apenas uma região da imagem de entrada. Deste modo, sem o deslocamento dos filtros sobre toda a imagem, as convoluções deixam de compartilhar os pesos. Esta característica confere à CNN a capacidade de aplicar ajustes finos nas imagens processadas, pois permite a identificação de eventuais padrões de alta frequência contidos em estruturas de frequências mais baixa.

2.3.4 Funções de Ativação

Para detectar as características existentes nos dados de entrada é necessário aplicar uma função de ativação sobre os mapas de características resultantes da convolução. Nos primeiros modelos de CNN, a implementação da camada de ativação consistia em aplicar a função *sigmoid* (Equação 2.18) em cada elemento dos mapas de características, assim como ocorre em uma rede neural tradicional.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.18)$$

A Figura 10 ilustra a função *sigmoid* que, ao longo do tempo, foi modificada para atender a novos requisitos em diferentes domínios. Por exemplo, em reconhecimento de objetos em imagens, tornou-se comum o uso da função *sigmoid* retificada ($abs(g_i \tanh())$), na qual g_i é um parâmetro de ganho otimizado durante o treinamento (LECUN; KAVUKCUOGLU; FARABET, 2010). Posteriormente, a função *sigmoid* retificada foi adaptada com regularizadores para garantir a competição entre características adjacentes nos mapas de características.




Figura 10 – Não-linearidade da função *sigmoid* aplicada na camada de ativação dos modelos iniciais de CNNs.
Fonte: o autor.

A função *Rectified Linear Unit* (ReLU) estabelece o valor 0 como limiar para os valores admitidos pela função, ou seja $f(x) = \max(0, x)$. A Figura 11 ilustra o formato da função ReLU.




Figura 11 – Não-linearidade da função ReLU, cuja aplicação aumentou a performance das CNNs em relação ao uso da função *sigmoid*. Fonte: o autor.

A função ReLU pode ser adaptada para permitir pequenos gradientes nas regiões em que assume valor 0 e as unidades da convolução não são ativadas. Assim, assume o formato da Equação 2.19, na qual α pode admitir um valor para a inclinação da função na parte negativa do domínio (MAAS; HANNUN; NG, 2013), ou ainda, um vetor cujos valores são otimizados pelo algoritmo de aprendizagem (HE et al., 2015).

$$f(x) = \begin{cases} x & \text{para } x > 0 \\ \alpha \cdot x & \text{para } x \leq 0 \end{cases} \quad (2.19)$$

2.3.5 Camada de Pooling

A última etapa de um estágio em uma CNN compreende a operação de *pooling*. Essa, consiste em gerar um sumário estatístico dos mapas de características por meio da aplicação de uma operação matemática em uma vizinhança. Em seguida, desloca-se essa vizinhança sobre cada mapa de característica.

A operação de *pooling* busca tornar as representações das características invariantes a pequenas translações. Ou seja, ainda que algumas características sofram pequenos deslocamento nas imagens de entrada, sua ativação será aproximadamente a mesma após o processamento na camada de *pooling*. Ao final, tem-se mapas de características com resolução reduzida, a partir dos quais, novas características serão extraídas nos estágios seguintes da rede.

A versão mais simples da operação de *pooling* consiste em calcular a ativação média da vizinhança (*mean pooling*) em cada mapa de característica. Alternativamente, a operação de *pooling* máximo (*max pooling*) calcula a ativação máxima da vizinhança (ZHOU; CHELLAPPA, 1988), como ilustrado na Figura 12.




Figura 12 – Operação de *pooling* máximo com vizinhança de tamanho 3. Nessa operação, seleciona-se o máximo valor de ativação da etapa de detecção. Fonte: Goodfellow, Bengio e Courville (2016).

Sob uma perspectiva global, a operação de *pooling* representa a adição de uma suposição *a priori* de que os padrões a serem apreendidos pela camada convolucional devem ser invariante a pequenas translações. Quando essa hipótese é verdadeira, implica o aumento da eficiência estatística da rede (GOODFELLOW; BENGIO; COURVILLE, 2016). Adicionalmente, promove-se um ganho computacional, uma vez que a redução na resolução dos mapas de características diminui o número de entradas a serem processadas no estágio seguinte da rede e, conseqüentemente, o uso de memória (GÉRON, 2017).

2.4 DEBLURRING

Chaudhuri, Velmurugan e Rameshan (2014) definem a operação de *blurring* como a convolução entre um filtro k e uma imagem latente I , conforme a Equação 2.20

$$y = K \otimes I + n, \quad (2.20)$$

n representa o ruído aleatório admitido. Na Equação 2.20, K , I e n são desconhecidos e, para obter a imagem nítida, é necessário realizar o processo inverso da convolução \otimes . No processamento de imagens, esse problema inverso é conhecido como deconvolução e pode admitir muitas soluções para K e I .

Para resolver esse problema, as abordagens podem variar de acordo com a disponibilidade de informações *a priori* sobre K e I . Nesse contexto, a operação de *deblurring* “não-cego” (NB, em acrônimo para *Nonblind Deblurring*) ocorre quando há disponibilidade de algum conhecimento sobre o filtro convolucional K , e se aplica tal conhecimento para obter a imagem latente I (WANG et al., 2009). Por outro lado, a operação de *deblurring* “cego” (BD, em acrônimo para *Blind Deblurring*) ocorre quando há inferência da imagem nítida I , por meio do processamento da imagem borrada Y , sem conhecimento adicional do filtro convolucional K (ZHANG; WIPF; ZHANG, 2013).

É possível classificar as metodologias para realizar BD em três abordagens. Na primeira, estão os métodos clássicos de processamento de imagens. Esses, buscam recuperar imagens nítidas por meio de operações como filtragem da imagem borrada (JIN et al., 2003; CHANG; HSIAO; HSIEH, 2008), Transformada de Fourier (JIANG; HAO, 2007) e transformação de *wavelet* (CHANG; VETTERLI, 2000; WINK; ROERDINK, 2004).

A segunda abordagem, combina a construção de imagens *a priori*, com técnicas discriminativas como MAP e modelos probabilísticos, para aumentar a resolução de imagens. Frequentemente, a aplicação dessa abordagem envolve realizar suposições sobre as características do filtro convolucional ou das imagens. Esse aspecto da abordagem discriminativa é adequadamente descrito por Schuler et al. (2016) (em tradução livre), quando afirma que:

“Usualmente esses métodos assumem alguma esparsidade para induzir imagens prévias para \mathbf{y} , e seguem um esquema iterativo e multi-escalar, alternando entre a estimação da imagem borrada e latente.”²

A imagem borrada é referenciada por \mathbf{y} . Além da suposição de filtros esparsos, é possível admitir que as imagens borradas possuem estatísticas Gaussianas (BABACAN et al., 2012). Em ambos os casos, o objetivo em realizar tais suposições é criar imagens *a priori*, que atuem como suporte na inferência do filtro convolucional.

Por fim, a terceira abordagem consiste em realizar “BD por aprendizado” (SCHULER et al., 2016), cujo nome é uma referência ao emprego de técnicas de aprendizagem de máquina (e.g. redes neurais ou CNNs) na recuperação de imagens nítidas. Com foco nessa abordagem, resultados efetivos e ideias inovadoras estão surgindo a partir da aplicação de redes neurais, principalmente com as CNNs, ou seja, os filtros convolucionais. Com a adoção das CNNs, a operação de BD se tornou viável, por meio da construção de modelos neurais, e do ajuste dos parâmetros desses modelos. Quando esse ajuste é realizado adequadamente, permite-se à rede apreender, a partir de exemplos, as características que geram o aspecto borrado em diferentes partes de uma imagem. Com essa abordagem, a BD se tornou a função de uma imagem borrada I e um conjunto de parâmetros \mathbf{p} , como apresenta a Equação 2.21.

$$y = \sigma(I, \mathbf{p}). \quad (2.21)$$

² “Usually these methods assume some sparsity inducing image prior for \mathbf{y} , and follow an iterative, multi-scale estimation scheme, alternating between blur and latent image estimation.”

3 TRABALHOS CORRELATOS

Neste capítulo será descrito o plano adotado para a revisão da bibliografia. Serão apresentados os trabalhos relacionados à operação de BD, buscando agrupá-los nas duas categorias mais observadas na literatura: métodos discriminativos e métodos baseados em aprendizagem. Em seguida, serão apresentados os trabalhos relacionados com o aumento de nitidez na inversão sísmica. Por fim, será apresentada a tabela comparativa entre os métodos existentes para o aumento de nitidez na inversão sísmica e o método proposto neste trabalho.

3.1 PLANO DE REVISÃO

Para esta revisão da literatura foram consultados os portais *Google Scholar*, *Science Direct*, *ACM Digital Library* e *IEEE Xplore*. A fim de listar os trabalhos relacionados, as buscas foram divididas em dois temas: o primeiro, relacionado às técnicas para realizar BD; e o segundo, relacionado às técnicas para obter o aumento de nitidez nas imagens da inversão sísmica.

Em relação às técnicas de BD, como mencionado na Seção 2.4, os métodos podem ser classificados como clássicos, discriminativos e baseados em aprendizagem. Atualmente, há trabalhos pontuais no sentido do aprimoramento de alguns métodos clássicos, com o intuito de superar as limitações que apresentaram no passado. Esse é o caso do método de BD com filtros de Wiener, que apresentava instabilidade na estimação do filtro, cuja aplicação gerava um efeito “anel” nas imagens estimadas. Recentemente, Li, Lv e Deng (2018) propuseram a incorporação de regularizadores na estimação dos filtros, por meio do método de mínimos quadrados. Com essa abordagem, foi possível superar com sucesso as limitações citadas e obter resoluções maiores em imagens de microscópio.

Os métodos discriminativos apresentaram bons resultados na remoção de ruído e na remoção do aspecto borrado causado por movimento (*blur motion*). Porém, o emprego das CNNs permitiu o aumento da nitidez em imagens com aspectos borrados diversos. Os principais trabalhos nesta área apresentaram modelos de CNNs treinados com pares de imagens de alta e baixa resolução, capazes de apreender um conjunto de distribuição de probabilidades para cada *pixel* da imagem borrada. Com a distribuição de probabilidades apreendida, é possível reclassificar cada *pixel* na faixa dos 256 valores possíveis em cada um dos três canais do sistema RGB.

Em relação ao aumento de resolução na inversão sísmica, os trabalhos coletados abordam o problema por meio de três estratégias: a primeira, consiste em processar o dado sísmico, a fim de recuperar parte dos elementos de alta frequência perdidos durante a aquisição. A segunda estratégia consiste em utilizar dados de alta resolução obtidos em poços, para calcular os modelos intermediários (acústicos e petrofísicos) e integrá-los no processo de inversão. Por fim, a terceira estratégia consiste na manipulação da *wavelet*, de modo a ampliar o espectro de frequência.

3.2 BD BASEADO EM MÉTODOS DISCRIMINATIVOS

O método discriminativo apresentado por Babacan et al. (2012), consistiu em aplicar a inferência Bayesiana para otimizar a estimação do filtro convolucional e da imagem latente. Embora dependesse da definição de um conjunto de imagens Gaussianas, *a priori*, essa abordagem superou o método discriminativo baseado na inferência por MAP, apresentado por Levin et al. (2011).

Hacohen, Shechtman e Lischinski (2013) exploram uma base de dados de imagens de alta resolução, a fim de encontrar alguma que contenha características correspondentes com a imagem borrada. Esse processo é iterativo e tenta otimizar a correspondência entre a imagem extraída da base de dados, o filtro e a imagem estimada. Embora Pan et al. (2014a) tenham apresentado uma generalização para o método, esse depende da ocorrência de imagens similares à imagem latente, as quais nem sempre estão disponíveis.

Pan et al. (2014b) desenvolveram uma abordagem na qual aplicam a regularização L_0 na definição de *priors*, baseadas em intensidade e gradiente, para realizarem BD em imagens de textos. Com essa abordagem, o método de otimização obtém resultados intermediários durante a estimação dos filtros convolucionais.

O método proposto por Tofighi et al. (2016) é baseado na adição de restrições de dois conjuntos convexos. O primeiro conjunto é a restrição de fase no domínio da transformada de Fourier. A segunda restrição consiste no conjunto epígrafe da variância total. Com o suporte do conjunto epígrafe da variância total da imagem, é possível estabilizar a restauração da imagem, uma vez que possibilita a definição automática dos limites superior e inferior da variância da imagem. O método apresentou resultados consistentes no aumento de nitidez em imagens de microscópios e pode ser facilmente parametrizado para realizar *deblurring* de imagens em outros domínios.

Embora tenham alcançado performances promissoras nos respectivos conjuntos de teste, os métodos citados, anteriormente, apresentaram uma limitação para lidarem com tipos de funções de *blurring*, diferentes dos *blur motion* (SCHMIDT; SCHELTEN; ROTH, 2011; DANIELIAN; KATKOVNIK; EGIAZARIAN, 2012; XIAO, 2018). Chakrabarti (2016) ressaltou ainda, que os métodos baseados em otimização descritos anteriormente são consideravelmente custosos do ponto de vista computacional. Lai et al. (2016) observaram que o uso de imagens *priors* genéricas (criadas a partir das suposições de filtros esparsos e imagens Gaussianas), desfavorecem a realização de BD em cenários reais. Em contrapartida, os métodos baseados em aprendizagem ganharam destaque com os resultados motivadores das CNNs no campo de visão computacional.

3.3 BD BASEADO EM APRENDIZAGEM

Jain e Seung (2008) apresentaram uma CNN, que permite reduzir o nível de ruído em imagens. A arquitetura da rede é composta por quatro camadas que realizam convoluções

com filtros de tamanho 5×5 . Nesse modelo, as camadas convolucionais intermediárias (da segunda até a quarta camada) são conectadas a um conjunto de 8 mapas de características, escolhidos aleatoriamente, a partir das convoluções realizadas nas camadas anteriores. Para treinar o modelo, os autores utilizaram um algoritmo estocástico de aprendizagem *on-line*, que consiste em calcular o valor médio de um conjunto de imagens e empregá-lo, inicialmente, no cálculo dos gradientes de uma rede de apenas uma camada. Em seguida, o algoritmo expande os pesos e treina uma nova rede composta por duas camadas e assim sucessivamente, até obter o modelo completo com quatro camadas. Os autores verificaram que o modelo proposto é capaz de superar os métodos clássicos baseados em transformação de *wavelet* e campo aleatório de Markov na filtragem de ruídos em imagens. Além disso, demonstraram que essa abordagem seria capaz de realizar a tarefa de BD tão bem quanto os métodos aplicados à época.

Kim, Lee e Lee (2015) propuseram um modelo recursivo de CNN, composto por três módulos: módulo de incorporação, módulo de inferência e módulo de reconstrução. Com essa estrutura, a rede realiza a extração de características, a inferência de cada *pixel* e a reconstrução da imagem. O módulo de inferência possui uma estrutura recursiva, que simula o aumento do número de camadas da rede sem aumentar o número de parâmetros. Essa abordagem, no entanto, pode levar ao aumento descontrolado dos gradientes da rede. Para lidar com esse problema, os autores adotaram o método de supervisão recursiva, no qual conectam a saída de cada camada convolucional à camada de reconstrução da CNN.

Sun e Ponce (2015) apresentaram um modelo de CNN capaz de inferir um conjunto de filtros candidatos para remover o aspecto borrado causado ao gerar uma imagem em movimento (*motion blur*). A rede é composta por duas camadas convolucionais ativadas com função ReLU, seguidas de camadas de *pooling* máximo. Adicionalmente, a estrutura contém uma camada densa, com ativação ReLU, e uma camada de classificação multiclasse na saída da rede. Esse trabalho se destacou dos demais por ter sido capaz de recuperar aspectos borrados não-uniformes, por meio da combinação com um modelo baseado em campo aleatório de Markov. Posteriormente, Hradiš et al. (2015) adaptaram esse modelo, com o intuito de aumentar a nitidez em imagens de textos.

Schuler et al. (2016) propuseram uma estrutura que combina os módulos de (a) extração de característica, (b) estimação de filtros e (c) estimação da imagem latente. O primeiro módulo realiza a extração de informações locais na imagem. Em seguida, as características extraídas são combinadas globalmente na etapa de estimação do filtro. Na última etapa, a rede utiliza o filtro estimado para atualizar a imagem latente. Para o treinamento do modelo, os autores utilizaram filtros criados a partir de coordenadas (x, y) amostradas em processos Gaussianos. Essas coordenadas estabelecem trajetórias para o efeito borrado e são escaladas para definirem os filtros convolucionais. Quando aplicados sobre as imagens nítidas, geraram imagens com aspectos borrados realísticos. Os pares de imagens nítidas e borradas são usadas na atualização dos pesos da rede. No entanto, os autores treinaram um modelo diferente para cada tipo de escalonamento do filtro convolucional, o que requer um número considerável de imagens para o treinamento. Além disso, a amostragem em processos Gaussianos limita o conjunto de soluções

para o filtro obtido.

Recentemente, Li et al. (2018) propuseram, através de uma CNN, um classificador binário, capaz de armazenar informações sobre a nitidez de uma imagem genérica. Essa informação é incorporada à estimação da imagem latente via MAP. Para realizar esta tarefa, os autores adotaram uma arquitetura que alterna entre camadas convolucionais, ativadas pela função ReLU, e camadas de *pooling* máximo. O último estágio da rede é composto por uma camada de *pooling* médio, seguida por ativação *sigmoid*. Com isso, foi possível diversificar a operação de BD para diferentes cenários.

Por fim, Min et al. (2018) combinaram o método clássico de transformação de *wavelet* com um modelo recursivo de CNN (semelhante ao modelo apresentado por Kim, Lee e Lee (2015)). A transformação de *wavelet* funciona como método de pré-processamento das imagens de entrada e extrai o conteúdo de frequências da imagem borrada. Em seguida, a estrutura recursiva reconstrói a imagem e remove as redundâncias criadas na etapa de identificação de características. O método superou o estado da arte para aspectos borrados por movimento e por filtros Gaussianos, mas apresentou limitações para imagens com aspectos borrados cuja a origem é desconhecida.

3.4 MÉTODOS DE AUMENTO DA RESOLUÇÃO NA INVERSÃO SÍSMICA

Farias, Freitas e Tygel (2008) combinaram o método CRS (*Common Reflection Surface*) com a técnica de balanceamento espectral para recuperar as altas frequências e promover o ganho de resolução vertical do dado sísmico. Com essa combinação, os autores aumentaram, consideravelmente, os valores de multiplicidades de empilhamento durante a geração da seção final do dado sísmico. O uso de multiplicidades elevadas aumenta a frequência crítica (frequência limite recuperável, na qual a amplitude do sinal e do ruído aleatório se igualam) e permite o aplainamento do espectro de amplitude. Desse modo, as frequências passam a ter amplitudes semelhantes, o que torna possível a detecção de estruturas mais delgadas. Para realizar o aumento elevado das multiplicidades, entretanto, é necessário dispor de um número igualmente elevado de CRSs, cuja soma resulte em apenas uma informação com ganho considerável na razão sinal-ruído. Deste modo, o método pode se tornar limitado no caso de disponibilidade apenas de algumas seções 2D.

Seguindo abordagens semelhantes, Jun e Bei (2010) e Wang et al. (2010) utilizaram perfis de poços para calcular modelos intermediários de pseudo impedância, com conteúdo adicional de alta frequência. Os autores derivaram, por exemplo, curvas pseudo acústicas a partir de curvas de potencial espontâneo (associadas ao contato entre rochas de diferentes propriedades elétricas, como a condutividade). Isso é possível, pois as curvas de potencial espontâneo são capazes de refletir as características litológicas da subsuperfície. Adicionalmente, as curvas acústicas foram utilizadas para agregar conteúdo de baixa frequência ao modelo intermediário. Por fim, os modelos intermediários de alta e baixa resolução foram incorporados ao processo de inversão sísmica, resultando em uma inversão com conteúdo adicional de frequência.

Outra abordagem para aumentar a resolução na inversão, consiste em realizar a deconvolução do dado sísmico, com base em diferentes suposições sobre a *wavelet* e sobre a série de refletividade. Recentemente, Nose-Filho et al. (2018) adotaram a hipótese de que os traços sísmicos são gerados por meio da mesma *wavelet*. Essa suposição permitiu que os autores definissem um conjunto de deconvoluções aplicáveis simultaneamente a um conjunto de traços sísmicos. Embora a adoção de *wavelet* única seja razoável no cenário em que o dado sísmico é gerado por apenas uma fonte, é certo que a resolução do dado nas regiões de maior profundidade estará prejudicada devido à dissipação da onda acústica. Ou seja, em cenários reais, os traços sísmicos vizinhos apresentam baixa variabilidade e alto ruído, o que representa uma importante limitação do método.

Por fim, Chen e Wang (2018) apresentaram uma abordagem baseada no escalonamento da *wavelet* para obter um espectro de frequência amplificado. Os autores exploraram a capacidade de escalonamento da transformada de Fourier, com o intuito de aumentar a resolução sísmica. O espectro de frequência de uma *wavelet* ($\omega(t)$), no tempo t , é representada por $W(f) = |W(f)|e^{i\phi(f)}$, em que f é a frequência, $|W(f)|$ é a amplitude e $\phi(f)$ é a fase do espectro. O método explora a propriedade da teoria de Fourier, segundo a qual a compressão da *wavelet* $\omega(t)$ por meio de um escalar $a > 1$ atende à seguinte equivalência no espectro (Equação 3.1):

$$\omega(at) \leftrightarrow \frac{1}{a} \left| W\left(\frac{f}{a}\right) \right| e^{i\phi(f/a)}. \quad (3.1)$$

Desse modo, quando $a > 1$, desloca-se a amplitude do espectro para as regiões de maiores frequências, aumentando a resolução da sísmica. Por outro lado, quando $0 < a < 1$, a amplitude do espectro é deslocada para as regiões de frequências mais baixas, diminuindo a resolução da sísmica.

O método apresentou um aumento considerável na banda de frequência e na frequência central da *wavelet*, o que implica em um aumento de resolução do dado sísmico. Entretanto, o método pode potencializar possíveis ruídos de alta frequência existentes no dado sísmico. Essa é uma situação possível, pois o filtro obtido com a compressão da *wavelet* apenas realiza a transferência de informação da alta frequência para o novo dado sísmico, não distinguindo entre sinal e ruído.

Constatou-se que os métodos de aumento de resolução da inversão estão principalmente relacionados ao processamento do dado sísmico e ao processamento da *wavelet*, a fim de aumentar o conteúdo de frequência durante a convolução com as refletividades. Há, ainda, os trabalhos que buscam incorporar elementos adicionais de alta frequência à inversão, por meio do cálculo de modelos intermediários, como modelos de pseudo impedância. O alcance dessa revisão não verificou trabalhos que realizem o pós-processamento do dado invertido, a fim de obter imagens mais nítidas. Esse, por sua vez, foi um dos princípios que norteou este trabalho. A Tabela 1 apresenta uma comparação entre os trabalhos relacionados e a proposta apresentada neste estudo.

Tabela 1 – Tabela comparativa com os trabalhos correlacionados.

	Dado sísmico	Dados <i>a priori</i>	Convolução	Pós-inversão
Farias, Freitas e Tygel (2008)	sim	não	não	não
Jun e Bei (2010)	sim	sim	não	não
Wang et al. (2010)	sim	sim	não	não
Nose-Filho et al. (2018)	sim	não	sim	não
Chen e Wang (2018)	sim	não	sim	não
Este trabalho	sim	sim	sim	sim

Fonte: o autor.

4 PROPOSTA PARA A RECUPERAÇÃO DAS ALTAS FREQUÊNCIAS DA IMPE- DÂNCIA ACÚSTICA PÓS-INVERSÃO

Neste capítulo serão apresentadas as ideias e as implementações amadurecidas durante esta pesquisa, que resultaram em um modelo de CNN, capaz de realizar o aumento de resolução da impedância acústica pós-inversão. Discute-se, ainda, as estratégias adotadas na definição dos conjuntos de dados e os resultados obtidos.

4.1 ALTERNATIVAS PARA A ABORDAGEM DO PROBLEMA

A metodologia implementada neste trabalho se baseou na construção, no treinamento e na avaliação de diferentes modelos de CNN. Estes modelos foram definidos como uma etapa de pós-processamento da inversão sísmica, como ilustrado na Figura 13. Os experimentos envolveram a realização da inversão sísmica por MAP para obter as imagens de baixa resolução, seguida do treinamento e teste da CNN com as imagens de referência e as imagens invertidas.

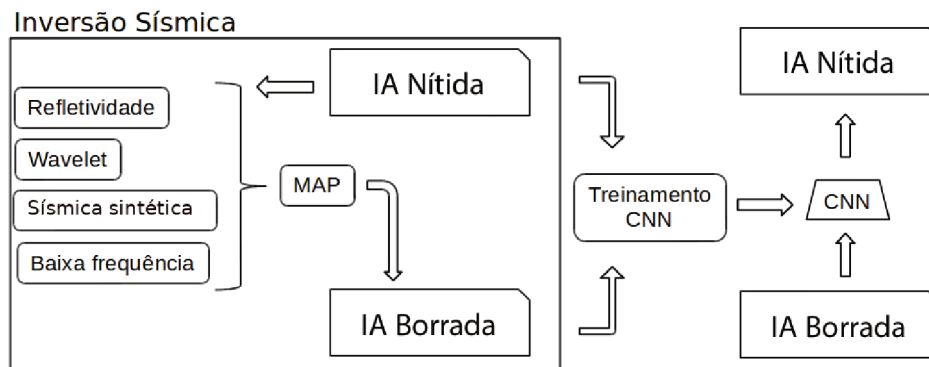


Figura 13 – Fluxograma que combina um modelo de CNN como método de pós-processamento da inversão sísmica. Fonte: o autor.

Na etapa de inversão, as séries de refletividades foram calculadas a partir de um conjunto de imagens de impedâncias acústicas sintéticas (alta nitidez). Em seguida, definiu-se uma *wavelet* Ricker de banda limitada, com a qual se calculou o dado sísmico sintético, adicionado de um ruído aleatório. Através de um filtro passa-baixa, obteve-se um modelo de impedância de baixa frequência. Por fim, com a sísmica e o modelo de baixa frequência, foi possível aplicar a inversão sísmica por MAP (FIGUEIREDO et al., 2014), cujo resultado é o modelo invertido com conteúdo limitado de frequência.

Na etapa seguinte, os pares de imagens de impedância acústica de alta e baixa nitidez foram utilizados no treinamento dos modelos de CNN. Após a escolha do modelo candidato, um novo conjunto de imagens invertidas foram apresentadas para a CNN, treinada para obter a imagem equivalente com conteúdo adicional de alta frequência.

4.1.1 O problema das estruturas acunhadas

Inicialmente, avaliou-se a capacidade da CNN na recuperação de conteúdo de alta frequência em um conjunto de impedâncias sintéticas que simulam estruturas geológicas em formato de cunha. O uso de modelos sintéticos para testar e parametrizar algoritmos é uma prática comum na caracterização de reservatório, pois permite estudar resultados sem interferências externas e realizar análises e interpretações eficientes (SANCEVERO; REMACRE; PORTUGAL, 2006).

De acordo com Harvey e MacDonald (1999), o uso de estruturas em formato de cunha é uma forma direta de analisar modelos sísmicos e processos de inversão, uma vez que reproduzem contextos como refinamentos estratigráficos e estruturas de canais. Com a aplicação da inversão, é possível recuperar a geometria e a dimensão da cunha modelada somente na região de maior espessura. Nas regiões de menor espessura, a inversão não permite a identificação da estrutura modelada, gerando, assim, incertezas na delimitação dos limites da cunha, e, conseqüentemente, uma imagem “borrada”, como mostrada na Figura 14.

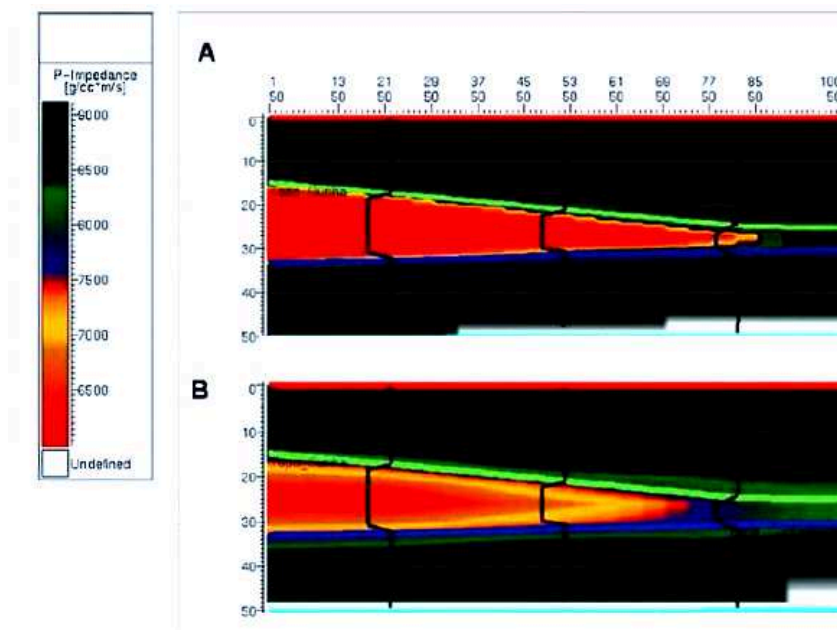


Figura 14 – Comparação entre o (A) modelo de referência e (B) resultado da inversão sísmica. É possível notar o a perda de definição na região mais fina da estrutura obtida com a inversão. Fonte: Adaptado de Sancevero et al. (2005).

Nesse sentido, o objetivo principal com a utilização dos modelos acunhados foi verificar a viabilidade da metodologia, por meio de um modelo simples, capaz de refletir situações próximas da realidade. Adicionalmente, a estrutura acunhada permite uma avaliação qualitativa da operação de BD em relação às regiões de menor espessura das cunhas, além de possibilitar a modificação das estruturas de forma simples.

4.1.1.1 Arquitetura da CNN

A arquitetura proposta inicialmente foi inspirada no modelo de CNN apresentado por Dong et al. (2014). Na proposta dos autores Dong et al. (2014), a rede é composta por uma camada de extração de características, como contornos e bordas, uma camada de ativação não-linear e uma camada convolucional de reconstrução. A estratégia adotada neste trabalho consistiu em adicionar uma nova camada de extração de características com ativação ReLU e utilizar a função tangente hiperbólica como ativação das camadas densas (totalmente conectadas) na etapa de reconstrução da rede. Essas medidas evitaram a discretização de cada *pixel*, como realizado no trabalho de Dahl, Norouzi e Shlens (2017). Além disso, tais medidas tornaram o modelo capaz de realizar a predição de valores contínuos para os *pixels*, e, portanto, mais apropriado para o processamento de propriedades petrofísicas.

A Figura 15 ilustra a arquitetura apresentada nesta seção, composta por dois componentes: (A) componente convolucional e (B) componente de regressão. O primeiro componente contém duas camadas convolucionais que mapeiam uma imagem borrada para um modelo de imagem não borrada, definindo os limites e os contornos de cada litologia. O segundo componente realiza a reconstrução da imagem e é composto por duas camadas de redução dimensional com ativação tangente hiperbólica.

Na arquitetura apresentada, cada camada convolucional contém 50 filtros de dimensões 5×5 iniciados aleatoriamente. Cada camada convolucional realiza a convolução padrão, de modo que, após cada operação de convolução, o filtro é deslocado uma posição em cada direção sobre a imagem. Adicionalmente, cada camada convolucional é seguida por uma operação de *pool* máximo para extrair a máxima ativação verificada na convolução e, com isso, inferir uma transição imediata entre as litologias identificadas.

Cada camada de *pooling* é seguida por ativações do tipo ReLU, de modo a permitir o aprendizado de características sensíveis nas imagens de entrada, em especial, nas regiões mais finas das cunhas. Adicionalmente, seguindo a sugestão proposta por Nair e Hinton (2010), a função de ativação ReLU acelera o processo de inferência dos filtros. Após o processamento nas camadas convolucionais, os resultados das convoluções são mapeados para uma camada densa (totalmente conectada), que reduz a dimensão das convoluções. Finalmente, a camada de saída aplica a função de ativação tangente hiperbólica para obter um valor contínuo de cada *pixel*.

4.1.2 O problema das terminações das estruturas de canais

O segundo problema investigado neste trabalho aborda um cenário de reservatórios de hidrocarbonetos mais próximo da realidade. Um reservatório de hidrocarboneto é um sistema complexo, delineado por várias características, por exemplo: geológica, petrofísica, geofísica e propriedades de dinâmica de fluidos (CASTRO; CAERS; MUKERJI, 2005). Frequentemente, não é possível realizar medições reais de todo o reservatório, devido às limitações tecnológicas




Figura 15 – Arquitetura de rede para recuperação bidimensional dos elementos de alta frequência em impedância acústica pós-inversão. Fonte: o autor.

e ao alto custo operacional para realizar esse procedimento. Desse modo, a inversão sísmica desempenha um papel importante na estimação dessas características, pois permite avaliar a existência de reservatórios promissores à exploração.

Além da perda das altas frequências nas regiões menores que a amostragem da *wavelet*, a inversão sísmica pode causar efeitos de deformação nas estruturas geológicas. Portanto, buscou-se o ajuste do modelo proposto, de modo a realizar BD nesses cenários, os quais podem se tornar mais complexos que os cenários dos modelos acunhados.

4.1.2.1 Arquitetura da CNN

A Figura 16 ilustra o modelo proposto, que consiste em uma arquitetura formada por quatro camadas multicanais. A camada de entrada possui dois canais, nos quais são apresentados os traços de impedância acústica borrada e o perfil sísmico equivalente. As duas camadas seguintes realizam operações de convolução. Na primeira, os filtros convolucionais possuem dimensões 10×1 e nenhuma suposição *a priori* é realizada sobre eles, de modo que os mesmos são inicializados aleatoriamente. Por meio das convoluções padrões, a rede apreende as estruturas espaciais em cada traço de impedância. Na segunda camada convolucional, ocorrem as convoluções localmente conectadas. Nessa camada, são criados 100 filtros convolucionais, portanto, o dobro da camada anterior. Porém, há uma redução na dimensão, sendo adotados filtros de tamanho 5×1 . Cada camada convolucional é seguida por uma operação de *pooling* máximo, cuja vizinhança possui tamanho 2. Por fim, duas camadas densas (totalmente conectadas) reduzem a dimensão dos dados, de modo que o traço de saída tenha a mesma dimensão do traço de entrada. A saída do modelo é a impedância acústica com mais nitidez que o traço apresentado na entrada.

Semelhante ao modelo anterior, a primeira camada convolucional contém 50 filtros. Por sua vez, a camada convolucional localmente conectada possui 100 filtros convolucionais, de modo a aumentar o detalhamento das características finas entre a primeira e a segunda camada. Preservou-se a função ReLU como camada de ativação das camadas convolucionais.

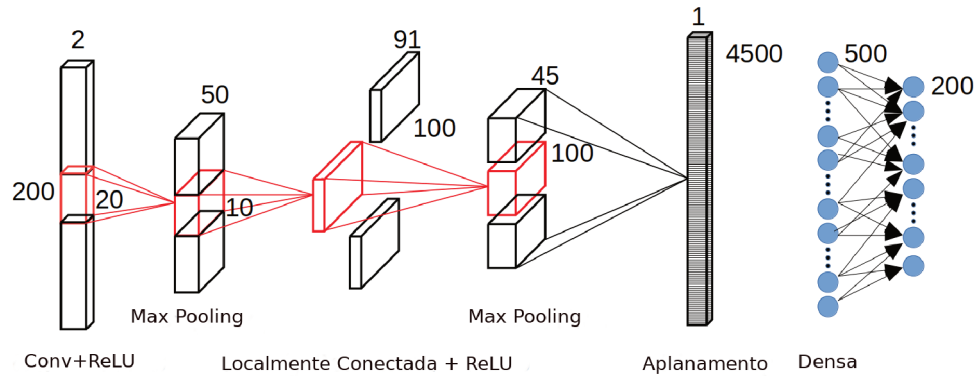


Figura 16 – Arquitetura de rede para recuperação unidimensional dos elementos de alta frequência em impedância acústica pós-inversão. Fonte: o autor.

4.2 FERRAMENTAS DE IMPLEMENTAÇÃO

Para implementar os modelos descritos anteriormente, utilizou-se a ferramenta Keras (CHOLLET et al., 2015), versão 1,0, que é uma biblioteca escrita em Python, de código aberto, criada com o intuito de facilitar a construção de modelos de aprendizagem de máquina utilizando o *framework* TensorFlow.

Por meio da sintaxe da linguagem Python, Keras abstrai a complexidade de implementação, de modo que as rotinas para a construção, o treinamento e o teste dos modelos são traduzidas para a estrutura do Tensorflow e executadas em segundo plano (*backend*). Neste trabalho foram utilizadas, ainda, a biblioteca de visualização de dados Matplotlib (HUNTER, 2007) e o aplicativo de computação científica Octave (EATON, 2002).

Os experimentos apresentados a seguir foram executados em um computador *desktop*, executando o sistema operacional Linux Ubuntu, com processador Intel®Core™i7-8700K, 64GB de memória RAM e placa de vídeo NVIDIA - GeForce RTX 1080 Ti.

5 EXPERIMENTOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados obtidos com os modelos de CNN propostos no capítulo anterior. Inicialmente, na Seção 5.1, será apresentado o conjunto de dados composto de imagens em forma de cunhas, seguido dos processos de parametrização e treinamento do modelo apresentado na Seção 4.1.1. Posteriormente, na Seção 5.2, será evidenciado o conjunto de dados Stanford VI, seguido dos procedimentos de parametrização e treinamento do modelo analisado na Seção 4.1.2. Por fim, serão exibidos os resultados obtidos e a comparação com as abordagens de BD utilizando os métodos propostos por Pan et al. (2014b) e Tofighi et al. (2016), discutidos na revisão da bibliografia.

5.1 ABORDAGEM BIDIMENSIONAL

A operação de BD das estruturas acunhadas ocorreu, primeiramente, por meio de uma abordagem bidimensional. Isso significa que os filtros que compõem as camadas convolucionais da rede possuem duas dimensões e a convolução com as imagens borradas ocorre deslocando-os em ambas as direções, horizontal e vertical. Com essa abordagem, verificaram-se os seguintes aspectos: (a) a capacidade da rede em apreender os padrões espaciais existentes nas imagens de treinamento de baixa resolução, como bordas e contornos, e (b) a capacidade de realizar a inferência do valor de intensidade de cada *pixel* da nova imagem.

5.1.1 Dados de Estruturas Acunhadas

A geração do conjunto de imagens que representam as litologias em forma de cunhas seguiu a estratégia apresentada por Sancevero, Remacre e Portugal (2006). Essa, consistiu em duas etapas: a primeira, criou um conjunto de imagens em forma de cunhas, de dimensões 32x32, cuja forma representa possíveis litologias para partes de um reservatório. A segunda, compreendeu o preenchimento das supostas litologias com valores de impedância acústica.

Visando manter a simplicidade das análises, o interior e o exterior das cunhas foram preenchidos com valores constantes de impedância. Para o cálculo da impedância acústica (Z), os valores de referência para a velocidade compressional (v) e para a densidade de rocha (ρ), ilustrados na Figura 17, foram aplicados na Equação 5.1 (MAVKO; MUKERJI; DVORKIN, 2009).

$$Z = \rho \cdot v \quad (5.1)$$

Na etapa seguinte, os modelos de impedância acústica foram filtrados com auxílio de filtros passa-baixa desconhecidos, configurado para realizar o corte das frequência em 4Hz. Assim, obteve-se o efeito borrado, como ilustrado na Figura 18.

Foram geradas 500 imagens de cunhas de referência, com formas diversas. Cada cunha foi rotacionada nos ângulos 90°, 180° e 270°, de modo que o conjunto de treinamento é formado

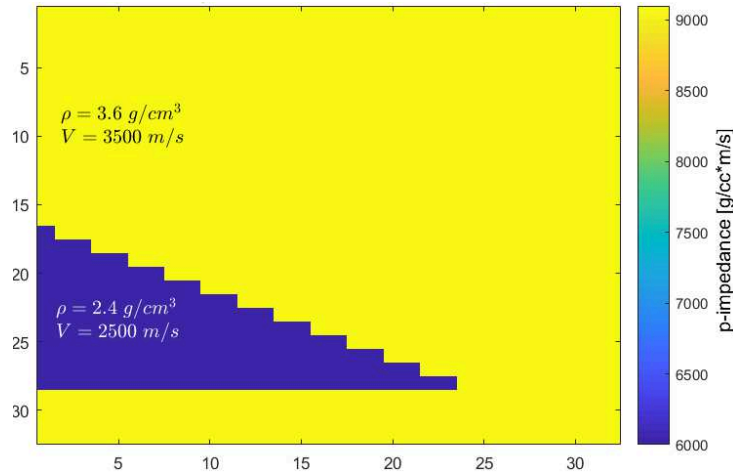


Figura 17 – Geração do modelo de impedância acústica. Cunha com valores de referência para densidade e velocidade compressional. Fonte: o autor.




Figura 18 – Modelo de impedância acústica borrada. Fonte: o autor.

por 2000 imagens para a representação litológica. Ao final, devido à implementação da função tangente hiperbólica na camada de saída da rede, os valores de impedância foram normalizados para o intervalo entre 0 e 1.

5.1.2 Treinamento do modelo bidimensional

Para o treinamento da CNN, foram apresentados à rede *mini-batches* (conjuntos de imagens) de 32 imagens em cada iteração. A taxa de aprendizado foi inicializada com valor 0,005 e configurada para decair exponencialmente ao longo de 150 iterações. Os valores dos filtros foram iniciados aleatoriamente e o algoritmo de Gradiente Descendente Estocástico com Momento (GDEM) realizou o ajuste dos pesos em cada camada, por meio do Erro Quadrático

Médico (MSE - *Mean Square Error*), calculado de acordo com a Equação 5.2.

$$MSE = \frac{(\sum_{i=1}^N (x_i - y_i)^2)}{N}, \quad (5.2)$$

Os resultados obtidos foram avaliados em termos da imagem sintética em alta resolução, da imagem sintética filtrada e da imagem obtida pela rede. Adicionalmente, um índice de similaridade baseado na transformada de Fourier, *Rank-FFT* (RFFT), foi utilizado como medida de desempenho na avaliação dos modelos treinados.

O RFFT foi apresentado por Narayanan e Thirivikraman (2015) e calcula o espectro de frequência de duas imagens para determinar o grau de similaridade entre elas. Esse índice é expresso por meio da Equação 5.3, na qual F_{1i} é o valor de intensidade do i -ésimo pixel da primeira imagem, enquanto F_{2i} é o valor de intensidade do i -ésimo pixel da segunda imagem. \bar{F}_1 e \bar{F}_2 representam os valores do espectro de amplitude da frequência média de cada imagem. Assim, quanto mais próximo de 1 o RFFT, mais similares serão as imagens comparadas.¹ Adicionalmente, serão apresentados os gráficos das magnitudes de cada frequência, com os quais é possível distinguir as regiões de frequências recuperadas e de adição de ruído.

$$RFFT = \frac{(\sum_{i=1}^N F_{1i}F_{2i} - N\bar{F}_1\bar{F}_2)^2}{(\sum_{i=1}^N |F_{1i}|^2 - N\bar{F}_1^2)(\sum_{i=1}^N |F_{2i}|^2 - N\bar{F}_2^2)}, \quad (5.3)$$

Os experimentos foram divididos em quatro cenários e serão apresentados nas subseções seguintes. O primeiro cenário analisa a capacidade de recuperação das altas frequências em cunhas posicionadas nos mesmos ângulos em que foram geradas no conjunto de treinamento (0° , 90° , 180° e 270°) e com os mesmos valores normalizados para a impedância acústica. No segundo cenário, os valores normalizados das impedâncias acústicas foram arbitrariamente modificados, a fim de verificar a capacidade de generalização da camada de regressão da rede. No cenário seguinte, as cunhas foram borradas com o filtro passa-baixa, configurado para frequências de corte diferentes. Por fim, os experimentos foram realizados com as cunhas cujo formato e a posição na imagem foram gerados aleatoriamente.

5.1.3 Experimento I: Cunhas Rotacionadas 90 Graus

Caso 1

O primeiro caso investigou a capacidade do modelo na recuperação das formas das cunhas e no aumento de resolução dos contornos e das bordas. Para alcançar esse objetivo, as imagens de treinamento e de teste foram construídas com os mesmos valores de referência para a velocidade compressional e a densidade de rocha. Assim, o único atributo que as difere é sua forma. O modelo foi treinado por 100 iterações e testado nas imagens apresentadas na Figura 19.

¹ Posteriormente, verificou-se a possibilidade de utilizar a *Structural Similarity* (SSIM) com métrica de similaridade mais adequada para o contexto deste trabalho.

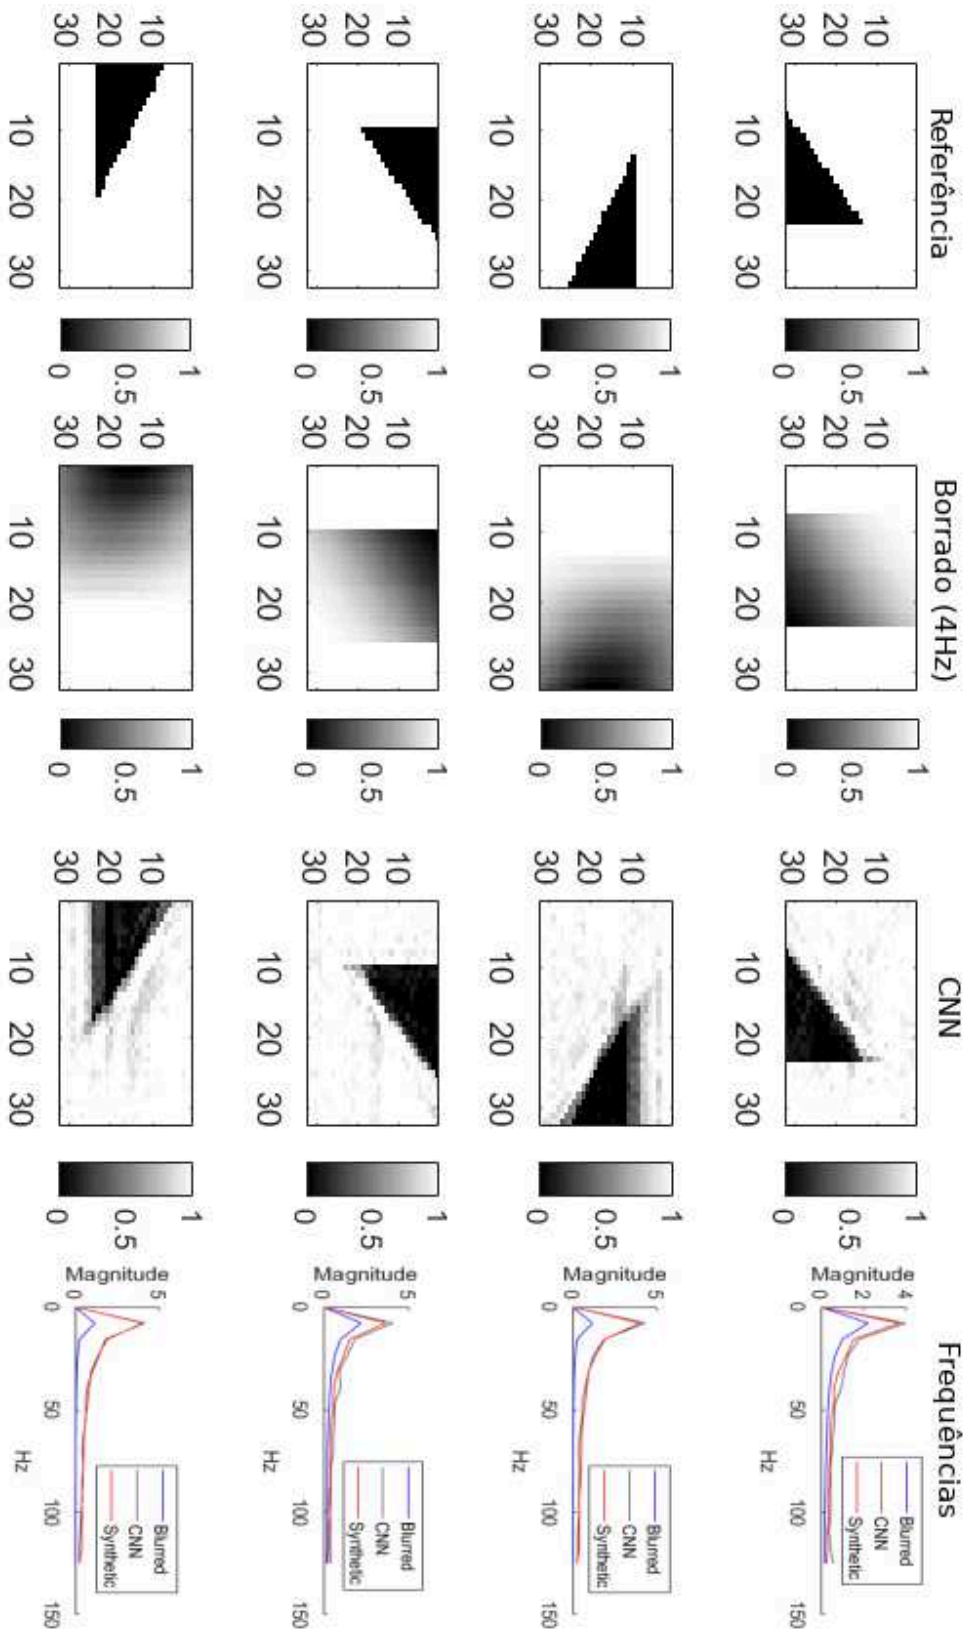


Figura 19 – Exemplos de aplicação da rede convolucional para recuperar a alta frequência em imagens que apresentam impedância acústica com valores normalizados e cunhas posicionadas em 0°, 90°, 180° e 270°: Caso 1. Fonte: o autor.

Na coluna de referência, estão ilustradas as imagens de referência em alta resolução com valores de impedância normalizados para o intervalo entre 0 e 1. Na coluna seguinte são apresentadas as imagens borradas com o filtro passa-baixa Gaussian, configurado com frequência de corte em $4Hz$, cujo efeito borrado gera uma região de grande incerteza com relação às transições entre as litologias. A terceira coluna (CNN) ilustra o resultado ao se apresentar a imagem borrada para o modelo de CNN.

Do ponto de vista qualitativo, é perceptível que as imagens produzidas pela CNN são mais nítidas, apresentam regiões de transição bem definidas e se aproximam das imagens de referência. A capacidade de adicionar elementos de altas frequências e sua relação com a recuperação de sinal nas imagens, são evidenciados nos gráficos de magnitude de frequências ilustrado na Figura 19. Os gráficos de frequências para as imagens de impedância acústica obtidas com a CNN mostram que o modelo recuperou com precisão o conteúdo de frequência das imagens borradas. É possível verificar o aumento de magnitude, das imagens obtidas pela CNN em relação às imagens borradas, na faixa de frequência entre $20Hz$ e $50Hz$ e entre $60Hz$ e $100Hz$.

Para cada imagem de saída da rede, são apresentados o RMSE e a métrica de similaridade (RFFT) em relação à imagem de referência e em relação à imagem borrada. Os valores na Tabela 2 mostram que os indicadores das imagens obtidas pela rede superaram os das imagens borradas, nos casos em que as imagens de teste possuem os mesmos padrões espaciais das imagens de treinamento. Em todos os casos observados, o erro das imagens da rede diminuiu e o RFFT indica maior similaridade com as imagens de referência em alta resolução. Os gráficos de recuperação de frequência mostram que as magnitudes das altas frequências das imagens da rede se assemelham às magnitudes das frequências das imagens de alta resolução.

Tabela 2 – Tabela de MSE e RFFT para cunhas borradas em $4Hz$ e recuperadas pela CNN: Caso 1.

Exemplo	Imagens borradas		Imagens CNN	
	MSE	RFFT	MSE	RFFT
1	0,1269	0,9843	0,0689	0,9815
2	0,1879	0,9621	0,0799	0,9837
3	0,1269	0,9843	0,0684	0,9925
4	0,1879	0,9676	0,0799	0,9837

Fonte: o autor.

Este caso de teste representa o resultado ideal esperado, pois se verificou a diminuição do erro de predição das imagens recuperadas pela rede e aumento da similaridade com a imagem de referência, assim como o aumento da banda de frequência, tornando-a similar, em relação ao espectro de frequência das imagens de referência.

Caso 2

No segundo caso, manteve-se o modelo treinado com o conjunto inicial de imagens e um novo conjunto de teste foi gerado. Para esse novo conjunto, os valores da impedância normalizada foram arbitrariamente modificados para valores intermediários iguais a 0,3 na li-

tologia da cunha e 0,7 na litologia em torno da cunha. Em seguida, as imagens foram borradas com o filtro passa-baixa e apresentadas à rede.

Observou-se a incapacidade do modelo em inferir tanto os novos valores de intensidade dos *pixels*, como as regiões de borda e contorno das cunhas. Essa limitação permitiu verificar que a capacidade da CNN relaciona as características apreendidas nas camadas convolucionais com o valor inferido na camada de regressão. Para verificar tal hipótese, um novo conjunto de teste foi gerado de modo que os padrões espaciais das cunhas foram mantidos, mas, em 30% das imagens do novo conjunto de treinamento, os valores das intensidades dos *pixels* foram atribuídos para o intervalo entre 0,3 e 0,7.

A Figura 20 apresenta as respostas da CNN para o novo conjunto de teste. É possível notar que a rede reproduziu as bordas e contornos apreendidos, mas, principalmente, foi capaz de inferir as novas intensidades dos *pixels*. É interessante notar que a adição de apenas 30% de imagens com os novos valores de intensidade de *pixel* no conjunto de treinamento tornou a rede capaz de definir as bordas e contornos das cunhas. Os valores das métricas na Tabela 3 reforçam a capacidade da rede, uma vez que se observam a redução mais contundente do erro e o aumento da similaridade (Exemplos 2 e 4).

Tabela 3 – Tabela de MSE e RFFT para cunhas borradas em 4Hz e recuperadas pela CNN: Caso 2.

Exemplo	Imagens borradas		Imagens CNN	
	MSE	RFFT	MSE	RFFT
1	0,0876	0,9463	0,0593	0,9694
2	0,1135	0,9093	0,0721	0,9693
3	0,0876	0,9463	0,0593	0,9694
4	0,1135	0,9101	0,0699	0,9730

Fonte: o autor.

As cunhas posicionadas horizontalmente apresentaram maior incerteza em relação à recuperação das bordas. Por outro lado, as cunhas posicionadas verticalmente apresentaram maior incerteza quanto à inferência dos valores dos *pixels*. Esse fato se reflete nos gráficos de recuperação de frequências da Figura 20. As magnitudes das frequências recuperadas foram acima das magnitudes das imagens de referência, o que indica que a rede adicionou, além de sinal, ruído nessa região, ao passo que recuperou apenas parte das frequências médias (entre 40Hz e 60Hz). Para as cunhas posicionadas horizontalmente, houve a recuperação das magnitudes nas regiões acima de 80Hz. Entretanto, para as cunhas posicionadas verticalmente, se verificou a adição de ruído nas frequências entre 60Hz e 80Hz e recuperação de parte do sinal acima de 80Hz.

A implementação deste experimento levou ao entendimento de que, para realizar a inferência correta dos padrões espaciais das cunhas, é necessário que os valores a serem estimados sejam suficientemente conhecidos pela rede. Embora haja valores intermediários de impedância na região de transição entre as camadas de litologias, esses não foram suficientemente aprendidos, possivelmente pela baixa amostragem de valores nesse intervalo. Isto significa que se deve incluir exemplos desse cenário no conjunto de treinamento da rede.

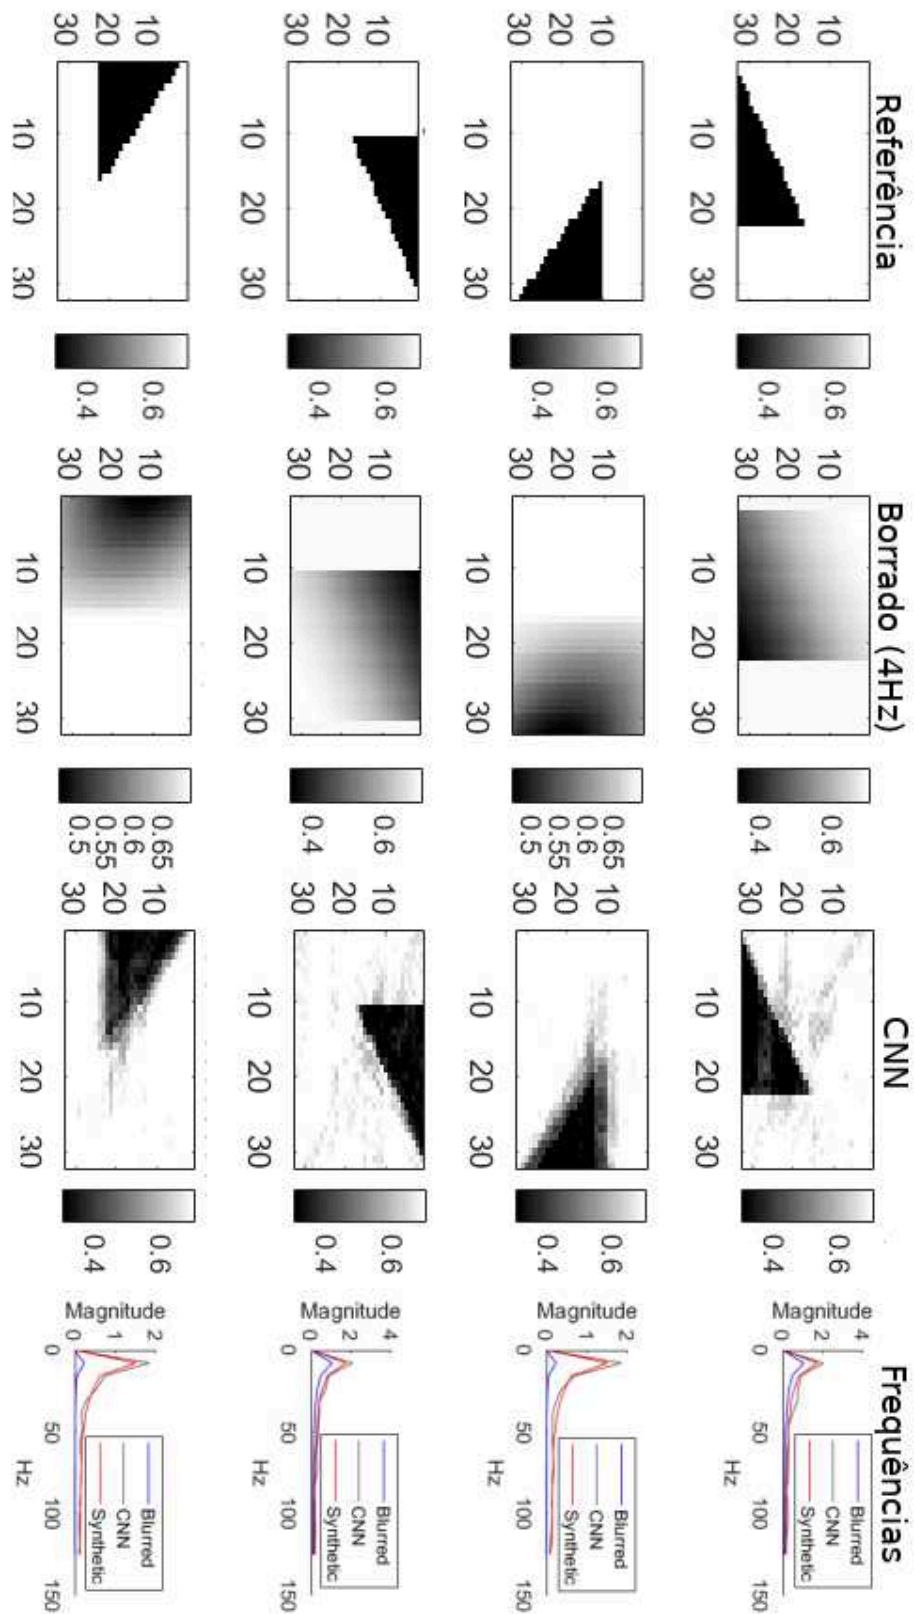


Figura 20 – Exemplos de aplicação da rede convolucional para recuperar a alta frequência em imagens impedância acústica com valores normalizados entre 0,3 e 0,7 e cunhas posicionadas em 0° , 90° , 180° e 270° : Caso 2. Fonte: o autor.

Caso 3

Em um cenário real, é possível que a atenuação do sinal sísmico gere diferentes perfis borrados, reproduzindo imagens com maior resolução na inversão das regiões mais rasas e a perda gradativa da resolução em função da profundidade. Para investigar esse cenário, cada imagem de referência foi borrada com uma frequência diferente. Para o cenário de teste, foram escolhidas imagens borradas em $2Hz$, $4Hz$, $6Hz$ e $12Hz$, ilustradas na Figura 21. Verifica-se que o modelo recuperou, com baixo erro e pouca adição de ruído, as frequências nas regiões, cuja frequência de corte é próxima a $4Hz$.

Neste cenário, a rede se tornou mais imprecisa à medida que a frequência de corte das imagens borradas se afastavam da frequência de corte das imagens de treinamento. Esse resultado foi particularmente interessante, pois esperava-se que as cunhas com maior nitidez fossem preservadas ao serem apresentadas à rede. Entretanto, como se pode notar na Figura 21, a cunha cuja frequência de corte está mais distante da frequência de corte das imagens de treinamento, foi totalmente deteriorada. Para imagens com resolução próxima à resolução “conhecida” pelo modelo, verificou-se um comportamento de maior capacidade de recuperação das formas da cunha, com maior nível de ruído, conforme se pode verificar na Figura 21.

Adicionalmente, os valores das métricas na Tabela 4 mostram que a frequência de corte está relacionada à forma da cunha recuperada pela rede. O Exemplo 1 obteve redução do MSE e a diminuição do RFFT, evidenciando a dificuldade encontrada pela CNN para estabelecer os limites precisos da litologia. O Exemplo 2, apresentou o comportamento esperado, visto no primeiro caso de teste desta seção. O Exemplo 3 evidenciou o comportamento ideal, embora com a inserção de ruído nas baixas e nas altas frequências. Por fim, no Exemplo 4, o erro aumentou e a similaridade diminuiu.

Tabela 4 – Tabela de MSE e RFFT para cunhas borradas em diferentes frequências de corte: Caso 3.

Exemplo	Imagens borradas		Imagens CNN	
	MSE	RFFT	MSE	RFFT
1	0,2074	0,9533	0,1981	0,9660
2	0,3136	0,8927	0,1770	0,9710
3	0,1539	0,9756	0,1385	0,9898
4	0,1904	0,9676	0,5561	0,8053

Fonte: o autor.

Este resultado traz um entendimento de que, além da forma das litologias e dos valores da propriedade, o espectro de frequência do dado de entrada para o treinamento da rede é um fator relevante para a sua posterior capacidade de recuperação das altas frequências. Consequentemente, para o aumento da resolução da imagem de teste.

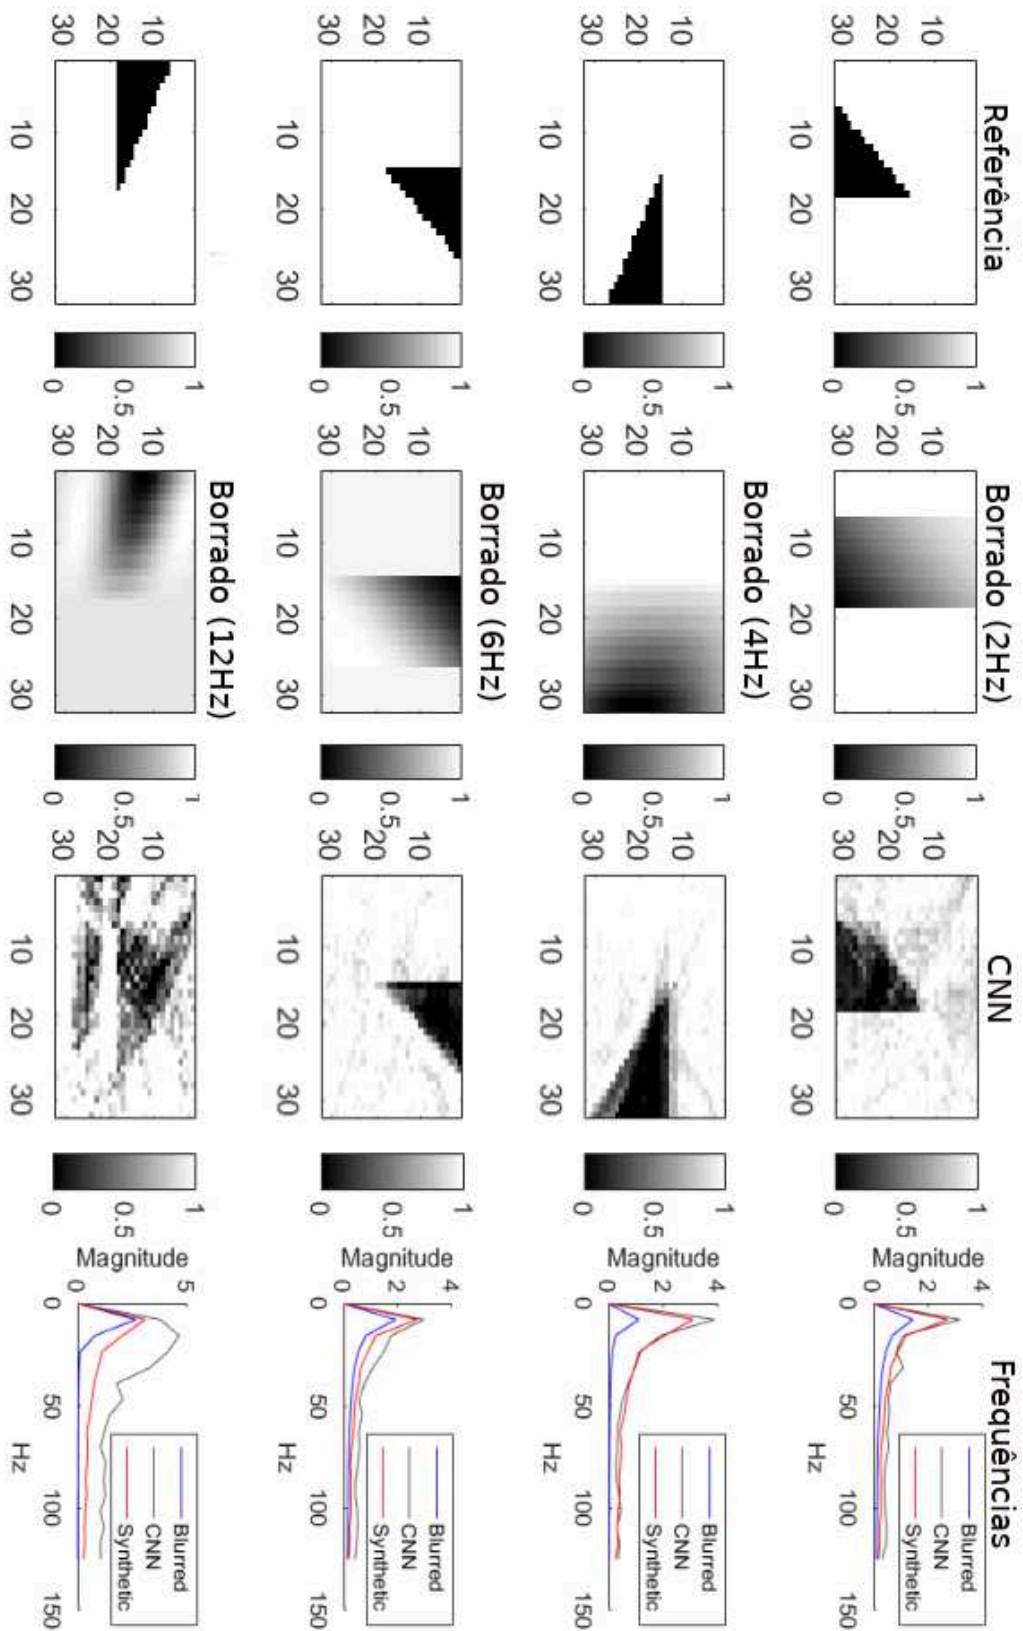


Figura 21 – Recuperação de frequência em cunhas posicionadas em 0° , 90° , 180° e 270° e impedância acústica borrada em diferentes frequências de corte: Caso 3. Fonte: o autor.

5.1.4 Experimento II: Cunhas com Formas e Ângulos de Rotação Aleatórios

O Experimento II compreendeu a recuperação das altas frequências em cunhas com formas e posições aleatórias. Foram geradas 600 imagens adicionais para compor o conjunto de entrada para uma nova série de treinamentos do modelo, compreendendo, portanto, 1000 imagens no total. As imagens adicionais são compostas de cunhas em formato triangular, com dimensões e posições aleatórias e foram borradas com o filtro passa-baixa, configurado para realizar o corte de frequência em $20Hz$. Um conjunto de imagens de teste foi gerado e está ilustrado na Figura 22.

Como se pode notar na Figura 22, as arestas das cunhas se tornaram mais nítidas em comparação às arestas das imagens borradas, entretanto, o modelo apresentou limitação na definição dos vértices e, portanto, os limites das estruturas foram extrapolados. Os gráficos de magnitudes mostram que houve a recuperação completa das baixas frequências. Porém, as médias e altas frequências apresentaram magnitude ligeiramente menor que as frequências das imagens de referências. Embora o Exemplo 2 (segunda linha na Figura 22) tenha apresentado magnitudes mais elevadas entre $15Hz$ e $40Hz$ e acima de $80Hz$, notou-se a adição significativa de ruído.

Ao observar os gráficos das frequências recuperadas na Figura 22, reforça-se a necessidade de apresentar à rede, durante o treinamento, a maior variedade possível de informações sobre litologias e frequências. Com isso, é possível diminuir a incerteza do modelo e tornar a recuperação da frequência e o aumento de resolução viáveis.

Na avaliação quantitativa na Tabela 5, as imagens obtidas na saída da rede apresentaram diminuição do MSE, evidenciando a capacidade preditiva da rede. Por outro lado, as imagens se tornaram mais dissimilares com a diminuição do RFFT. Esse fato pode estar relacionado com o aumento da complexidade e o número pouco representativo das novas formas de cunhas.

Tabela 5 – Tabela de MSE e RFFT para cunhas borradas em posições e formatos aleatórios: Caso 4.

Exemplo	Imagens borradas		Imagens CNN	
	MSE	RFFT	MSE	RFFT
1	0,2310	0,9241	0,2170	0,9146
2	0,2180	0,9441	0,2155	0,9280
3	0,2196	0,9464	0,1957	0,9447
4	0,2234	0,9562	0,2031	0,9603

Fonte: o autor

5.2 ABORDAGEM UNIDIMENSIONAL

A abordagem bidimensional apresentou resultados motivadores, na medida em que tornou as imagens cunhas mais nítidas. Os resultados obtidos com esse modelo motivaram a tentativa de treinar a mesma arquitetura usando um conjunto de dados com características

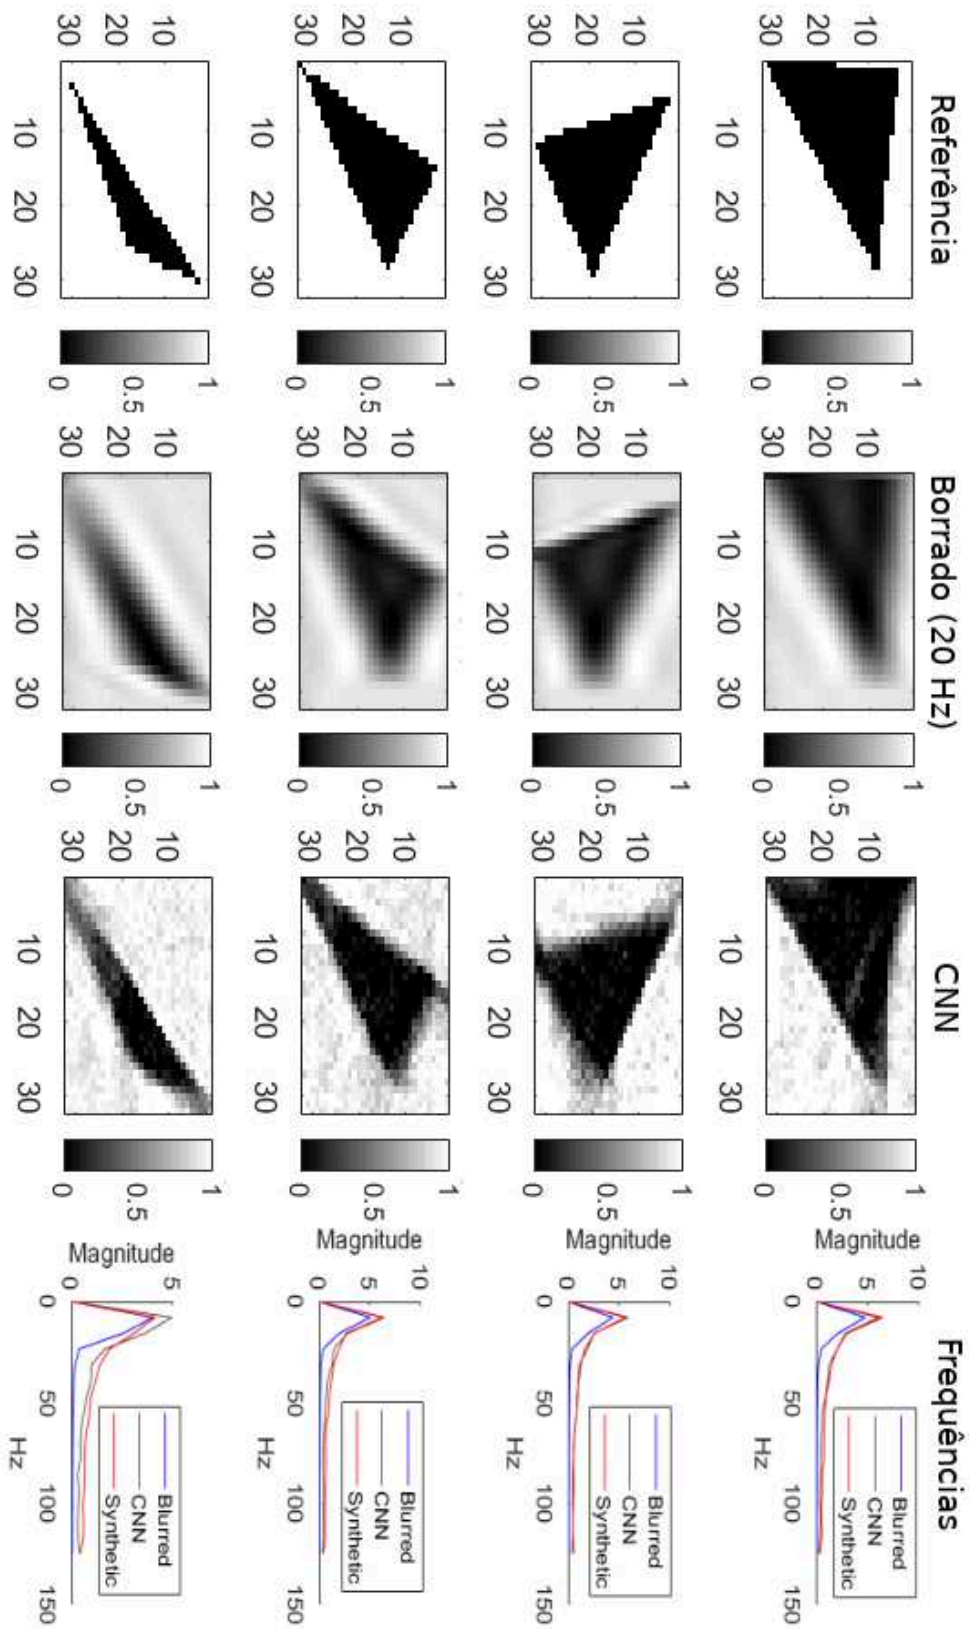


Figura 22 – Exemplos de aplicação da rede convolucional para recuperar a alta: Formas e ângulos aleatórios.
Fonte: o autor.

próximas às de um cenário de reservatório real, composto por diferentes estruturas de canais. Entretanto, observou-se uma incapacidade do modelo bidimensional em aumentar a nitidez de imagens compostas por emaranhados de canais. Assim, buscou-se, por meio da arquitetura unidimensional proposta na Subseção 4.1.2, uma alternativa mais simplificada para cenários mais complexos.

Motivou a adoção de uma abordagem unidimensional, o fato de que cada seção do reservatório pode ser apresentada traço a traço à rede durante o treinamento. Desse modo, os padrões apreendidos se tornariam mais simples e permitiriam um processo mais eficaz no aprendizado da rede, garantindo uma convergência mais rápida. Além disso, a abordagem unidimensional permite a utilização da impedância acústica de alta resolução, calculada a partir dos dados de perfis de poços, tanto para o treinamento quanto para a aplicação da rede.

5.2.1 Dados de Reservatório: Stanford VI

Para avaliar o modelo de BD unidimensional, foram utilizados os dados do reservatório Stanford VI (LEE; MUKERJI, 2012). O reservatório Stanford VI é um conjunto de dados criado por simulação de fluxo, com o intuito geral de testar qualquer algoritmo para a modelagem e a caracterização de reservatório (CASTRO; CAERS; MUKERJI, 2005). O sistema exibe uma estrutura com dimensões realísticas e disponibiliza amostras de propriedades petrofísicas e atributos sísmicos.

O Stanford VI representa um sistema de canais meandantes composto de três camadas. Em conjunto, as camadas formam um modelo com dimensões de 3,7 km de largura e 5 km de comprimento, com topo mais raso a 2,5 km e topo mais profundo a 2,7 km de profundidade. O reservatório possui, ainda, uma representação em forma de grade estratigráfica de dimensões $150 \times 200 \times 200$ células. Cada célula corresponde às dimensões de 25 metros horizontalmente e um metro verticalmente. Na primeira camada do Stanford VI, se observa um sistema de canais meandantes de baixa sinuosidade representado por quatro fácies, cuja característica estratigráfica é ilustrada na Figura 23.




Figura 23 – Canais meandantes de baixa sinuosidade compostos por quatro fácies: várzea (azul escuro), depósitos internos (azul claro), canais (amarelo) e limites (vermelho). (A) Estratigrafia e (B) cubo cartesiano. Fonte: Castro, Caers e Mukerji (2005).

A segunda camada compreende um sistema de canais meandrantemente igualmente representado por quatro fácies. A estratigrafia da segunda camada é ilustrada na Figura 24.

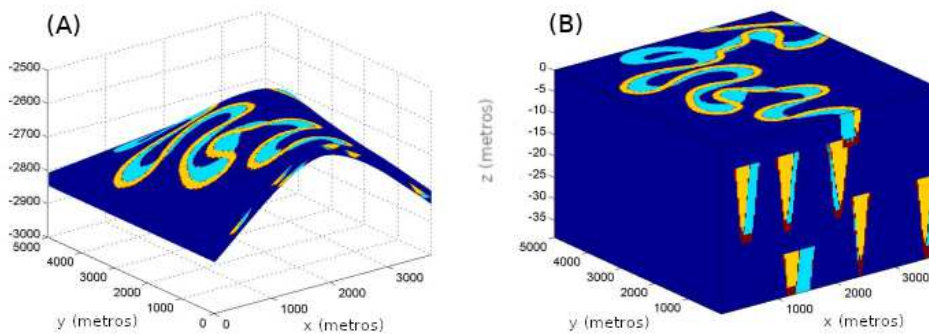


Figura 24 – Canais meandrantemente altamente sinuosos compostos por quatro fácies: planície de inundação (azul escuro), depósitos internos (azul claro), canais (amarelo) e limites (vermelho). (A) Estratigrafia e (B) cubo cartesiano. Fonte: Castro, Caers e Mukerji (2005) (2005).

Por fim, a terceira camada representa um conjunto de depósitos deltaicos, composto por duas fácies e cuja estratigrafia é ilustrada na Figura 25.

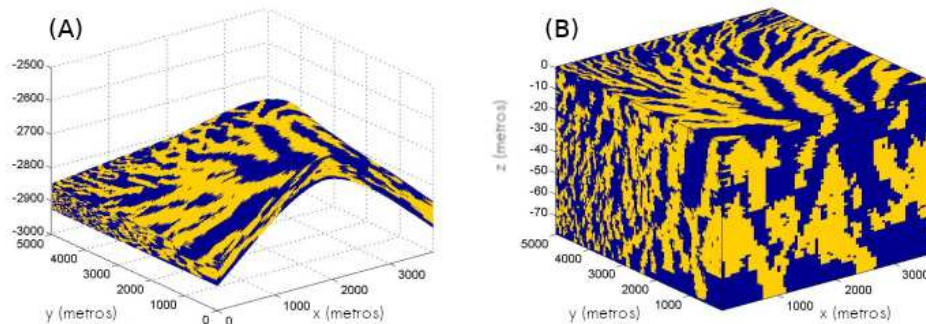


Figura 25 – Depósitos de planície deltaicos compostos por duas fácies: planície de inundação (azul escuro) e canais distributários (amarelo). (A) Estratigrafia e (B) cubo cartesiano. Fonte: Castro, Caers e Mukerji (2005).

As camadas de impedância acústica do reservatório foram empilhadas e o modelo resultante é ilustrado na Figura 26.

5.2.2 Treinamento do modelo unidimensional

O conjunto de dados Stanford VI contém 200 seções, cada uma com 150 traços de impedância acústica. Deste modo, o cubo completo compreende 30000 traços de impedância acústica nítida. Para o treinamento do modelo unidimensional apresentado na Subseção 4.1.2, foram amostrados, aleatoriamente, 10000 traços de impedância acústica nítida no conjunto de dados Stanford VI. Foram selecionados ainda os traços equivalentes no conjunto de impedância invertida (com baixa nitidez) e no conjunto referente à sísmica do Stanford VI. Por sua vez, os traços de baixa nitidez e do dado sísmico foram divididos em *mini-batches* contendo




Figura 26 – Modelo de impedância acústica Stanford VI Reservoir. Fonte: Castro, Caers e Mukerji (2005).

10 traços de impedância. Os *mini-batches* são subconjuntos dos dados, que são apresentados simultaneamente na camada de entrada da rede durante a etapa de treinamento.

A taxa de aprendizagem da rede foi inicializada com valor 0,001 e o modelo foi treinado por 150 épocas (rodadas de treinamento em que os dados são apresentados ao modelo). Os pesos da rede foram iniciados aleatoriamente e o algoritmo *Adam* (KINGMA; BA, 2014) foi utilizado para otimizar a função Erro Absoluto Médio.

O critério de parada do treinamento, portanto, consistiu em calcular o erro desse conjunto de teste em cada época do treinamento e em salvar a configuração de pesos a cada mínimo atingido. A Figura 27 ilustra o erro do treinamento e o erro do conjunto de teste em cada época.

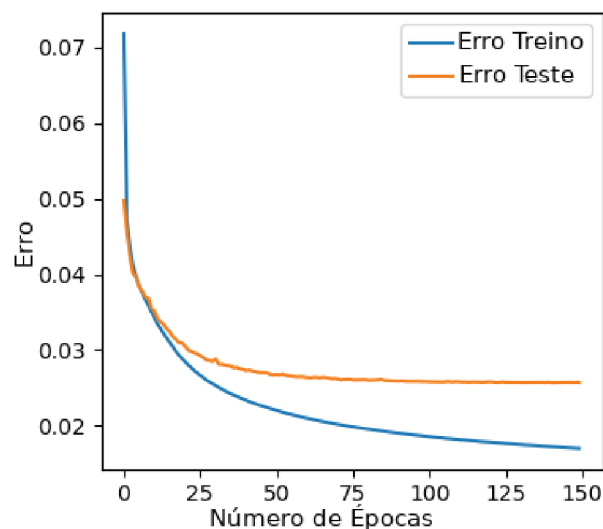


Figura 27 – Erros para o conjunto de treinamento e teste em cada época do treinamento do modelo. Fonte: o autor.

Após o treinamento, foram selecionadas 10 seções adicionais de impedância invertida e do dado sísmico, totalizando 1500 traços, os quais foram utilizados como conjunto de teste

do modelo treinado. Os traços de teste foram selecionados de forma contígua, pois, deste modo, tornou-se possível a visualização dos resultados obtidos com a rede como imagens em duas dimensões. As imagens resultantes apresentaram maior resolução e os elementos de alta frequência esperados.

Observando em detalhes os resultados para duas seções, é possível notar que houve uma recuperação substancial dos eventos em camadas delgadas. Na Figura 28, as setas apontam para duas regiões de transições entre canais em que, nitidamente, o modelo recuperou elementos de alta frequência. Uma vez que os traços foram apresentados individualmente, nota-se que os valores de impedância foram devidamente recuperados, garantindo a resolução vertical de cada traço.

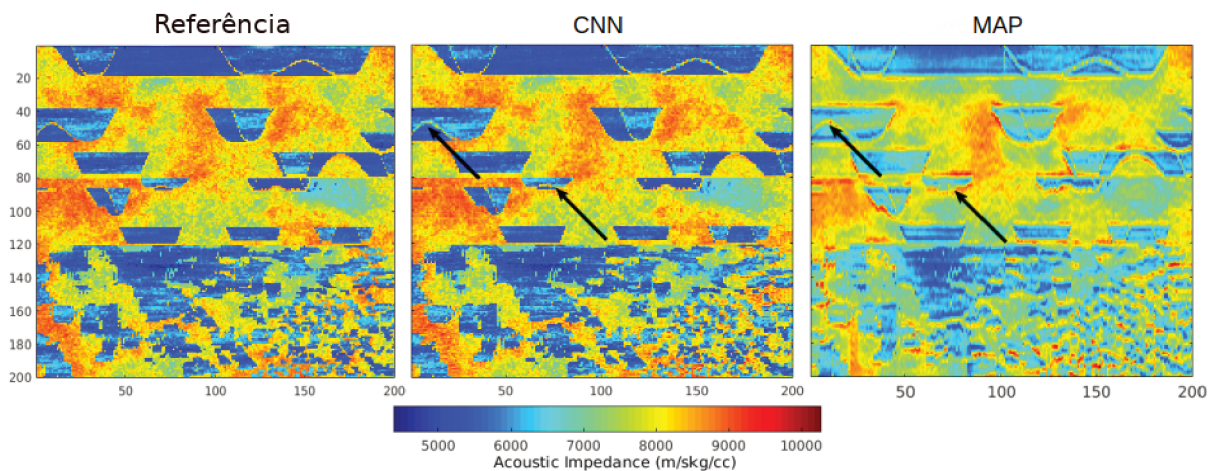


Figura 28 – Resultado da recuperação de frequência obtidos para um conjunto de teste. Plaície de inundação e intersecções entre canais são evidenciados. Da esquerda para direita: imagem de referência da impedância acústica, resultado da CNN e impedância invertida. Fonte: o autor.

Por sua vez, na Figura 29, as setas apontam para as regiões em que o modelo foi capaz de corrigir pequenas deformações geométricas criadas durante o processo de inversão, as quais, usualmente, ocorrem em características deposicionais como canais. É possível observar, na estrutura geológica apontada pela seta superior, que as regiões de afinamento, à direita e à esquerda da estrutura geológica, foram devidamente recuperadas, semelhante à recuperação das estruturas acunhadas observadas na Seção 5.1. As correções apontadas na figura evidenciam que o modelo, além de recuperar os valores de impedância, deslocou-os verticalmente para as regiões corretas na imagem.

A observância na recuperação de sinal de alta frequência é um resultado relevante neste trabalho, pois o espectro adicional observado nas imagens recuperadas pela rede está associado à inserção de sinal de alta frequência, ao invés de ruído. Nesse sentido, foram calculadas as magnitudes das frequências recuperadas nos traços de impedância, apresentados anteriormente (Figura 28 e Figura 28). Essas magnitudes são ilustradas na Figura 30-(a), na qual é possível observar a recuperação completa das baixas e médias frequências (aproximadamente entre $1Hz$ e $45Hz$), com a sobreposição do conteúdo de frequência dos traços de referência (linha verme-

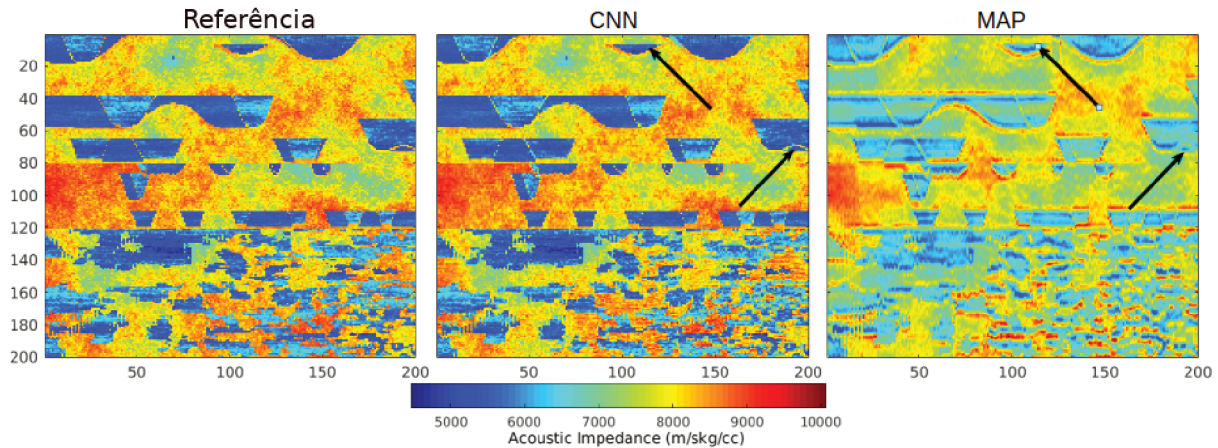


Figura 29 – Resultado de recuperação de frequência para um conjunto de teste. As setas indicam planícies de inundação e intersecção entre canais. Da esquerda para direita: imagem de referência da impedância acústica, resultado da CNN e impedância invertida. Fonte: o autor.

lha) e dos traços obtidos com a CNN (linha preta). Por sua vez, nas regiões das altas frequências (acima de 60Hz) observa-se que as magnitudes dos traços obtidos com a CNN são próximas às magnitudes dos traços de referência.

A Figura 30-(b) ilustra o percentual de recuperação para cada frequência. Como se pode notar, a CNN recuperou em torno de 100% da frequência do sinal existente na imagem borrada (entre 4Hz e 60Hz). Esse, por sua vez, é um resultado esperado, uma vez que se trata da banda de frequência da *wavelet* utilizada na inversão e, portanto, existente nos traços de impedância invertida. Por outro lado, o modelo recuperou, ainda, todo o espectro de frequência abaixo de 4Hz , assim como adicionou de 70% a 90% do espectro de frequência acima de 60Hz . Uma vez que a faixa acima de 60Hz está ausente na imagem borrada, nota-se que o modelo de CNN apreendeu as relações existentes entre os perfis sísmicos e a impedância acústica nítida e os reconstruiu nas imagens de teste.

Deve-se notar que a resolução horizontal apresentou maior definição que a resolução vertical. Esse fato pode estar relacionado à assinatura da *wavelet* e/ou ao processo de deconvolução unidimensional, cuja incerteza está associada à direção vertical. O aumento na resolução vertical é particularmente importante, pois está relacionada aos eventos nos quais as camadas se tornam mais finas e a porosidade diminui, assim, a resposta sísmica.

Por outro lado, o aumento da resolução vertical contribui para a avaliação da conectividade vertical no reservatório. Isso ocorre, por exemplo, na visualização de camadas finas de folhelho que atuam como barreira para a injeção de água e afetam a produção e pressurização do reservatório.

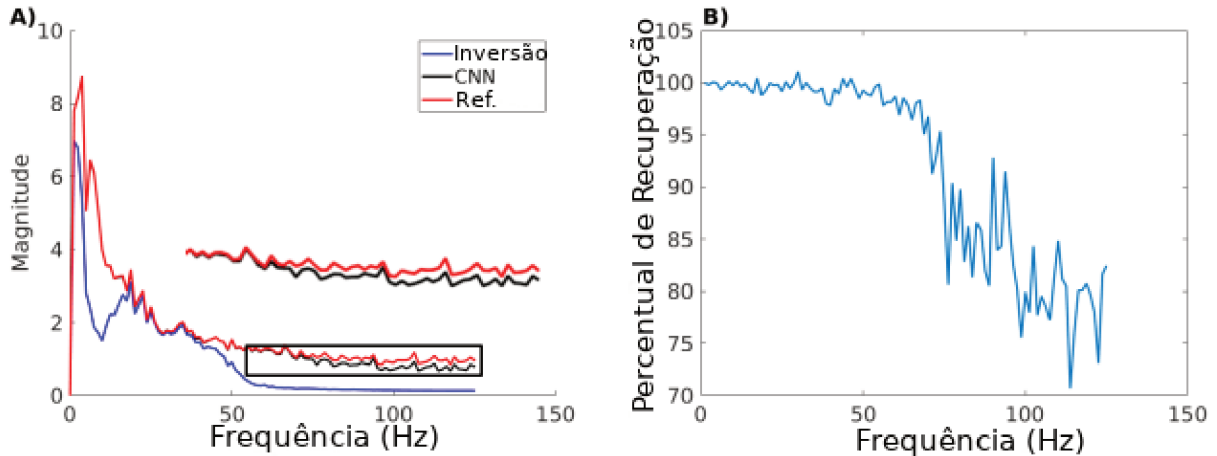


Figura 30 – (A) comparação entre os espectros de frequência das imagens de impedância acústica real, a imagem da inversão MAP e as imagens de saída da CNN. (B) percentual de recuperação para cada magnitude de frequência. Fonte: o autor.

5.3 VALIDAÇÃO DOS RESULTADOS

A validação dos resultados obtidos neste trabalho ocorreu por meio do cálculo dos picos de razão sinal-ruído (PSNR, do inglês *Peak Signal-to-Noise Ratio*). O PSNR é uma medida de processamento de sinal que compara um certo sinal processado com o sinal original. Assim, o PSNR representa uma relação direta do sinal antes e após o processo de degradação. Matematicamente, o PSNR é descrito pela Equação 5.4, na qual $\max(I_{real})$ representa o valor máximo do sinal observado entre a imagem real, e o MSE entre as imagens.

$$PSNR(I, I_{real}) = 10 \times \log_{10} \left(\frac{\max(I_{real})}{MSE_{I, I_{real}}} \right) \quad (5.4)$$

Para verificar a validade dos resultados obtidos com a CNN, as seções de impedância invertida foram submetidas aos métodos de *deblurring* apresentados por Pan et al. (2014b), Tofghi et al. (2016) e os valores de PSNR foram calculados.

O método proposto por Pan et al. (2014b) funciona por meio da incorporação do dado de fase da Transformada de Fourier e da função de variância total da imagem, à função de deconvolução durante a estimação do filtro convolucional². Para aplicar esse método na recuperação de altas frequências da impedância acústica, foram definidos um conjunto de valores para o tamanho do filtro convolucional, os quais foram obtidos com função gaussiana.

Adicionalmente, as imagens obtidas com a CNN foram comparadas com as imagens processadas com o método de BD proposto por Tofghi et al. (2016). Embora tenha sido desenvolvido originalmente para realizar BD em imagens de texto, os autores disponibilizaram uma adaptação para a aplicação em imagens genéricas, utilizada no processamento das imagens invertidas de impedância³.

² <https://sites.google.com/site/jspanhomepage/10rigdeblur>

³ <http://signal.ee.bilkent.edu.tr/BlindDeconv/BDeconv.rar>

Tabela 6 – Resultados da operação de BD para as seções de impedância acústica invertida com método MAP. São apresentados os valores de PSNR (dB) para cada uma das seções em relação à seção original. A última linha apresenta o valor médio do PSNR referente a cada método de BD.

Imagem	Inversão MAP	Pan et al. (2014b)	Tofighi et al. (2016)	CNN
1	19,6979	19,7415	19,6327	27,8631
2	19,5035	19,4891	17,2928	27,4324
3	20,3216	20,3422	20,1731	31,3928
4	21,1780	21,1708	16,8785	28,5792
5	19,3718	19,3983	15,1227	26,7589
6	21,3685	21,3688	18,6675	31,2996
7	20,0121	19,9671	15,4688	28,3334
8	18,9247	18,9409	18,6212	26,6847
9	18,8902	18,8656	15,0667	31,0684
10	19,4475	19,4138	19,0943	27,1089
Média	19,8716	19,8372	17,4105	28,6522

Fonte: o autor.

Do ponto de vista quantitativo, os valores de PSNR apresentados na Tabela 6 ratificam a superioridade da CNN na recuperação das altas frequências para cada uma das dez seções que compõem o conjunto de teste do Apêndice A. De acordo com os valores, é possível notar que os melhores resultados para o aumento da resolução da impedância acústica foram obtidos com o método proposto neste trabalho. O método descrito por Pan et al. (2014b) não foi capaz de recuperar os detalhes de alta frequência desejados e tornou as imagens ainda menos nítidas que as imagens invertidas. Por sua vez, o método proposto por Tofighi et al. (2016) apresentou PSNR superior às imagens da inversão, o que sugere algum ganho de resolução, porém, consideravelmente inferior ao obtido com a CNN.

Os métodos propostos por Pan et al. (2014b) e Tofighi et al. (2016) foram aplicados na realização de BD em imagens de texto e de microscópio, respectivamente. Para aplicar esses métodos no contexto do aumento de resolução da impedância acústica na inversão sísmica, foram realizadas adaptações relacionadas à dimensão e aos valores dos dados de entrada. Além disso, foram testadas diferentes parametrizações para cada um dos métodos, como o tipo de inicialização dos filtros convolucionais. A incerteza relacionada com a parametrização ideal dos métodos pode ter limitado os resultados obtidos, resultando em valores maiores de erro (MSE) e, por consequência, pode ter gerado valores baixos para os PSNR das seções de teste.

5.4 VERIFICAÇÃO ESTATÍSTICA

A aplicação da CNN no conjunto de teste alcançou um ganho médio no PSNR de 8,7806 em relação ao PSNR médio das seções invertidas. Para avaliar se o ganho de resolução é estatisticamente significativo, realizou-se um teste t sobre o aumento do PSNR. O teste ocorreu segundo a hipótese nula de que as imagens obtidas com os diferentes métodos possuem valores de PSNR iguais em média, embora com variâncias distintas. A confirmação da hipótese nula (H_0) implicaria na diferença nula entre as médias dos PSNR.

Tabela 7 – Resultados do teste t na comparação do modelo de CNN com o método proposto por Pan et al. (2014b).

Estatísticas	Valores
h	1
t	13,3330
p-valor	$8,9607^{-09}$
IC	7,3540 - 10,2107
df	12,5366
Média de P'	19,8716
Média de P	28,6522

Fonte: o autor.

Tabela 8 – Resultados do teste t na comparação do modelo de CNN com o método proposto por Tofighi et al. (2016).

Estatísticas	Valores
h	1
t	12,9737
p-valor	$1,4240^{-10}$
IC	9,2609 - 12,8398
df	17,9991
Média de P'	17,6018
Média de P	28,6522

Fonte: o autor.

P representa os valores de PSNR obtidos com um método da literatura e P' os valores de PSNR obtidos com a aplicação da CNN. Assim, foram definidas as seguintes hipóteses:

- H_0 : P e P' são iguais e a diferença entre as médias é zero.
- H_1 : A média de P' é maior que a média de P .

Aceitar a hipótese alternativa H_1 sugere que a recuperação de frequência obtida com a CNN é superior ao método da literatura, levando-se em consideração o PSNR como métrica de análise.

Inicialmente, o teste t foi aplicado com significância de 95% em relação a CNN e o método proposto por Pan et al. (2014b). A Tabela 7 apresenta os resultados do teste t .

O p -valor para o teste t é $8,9607^{-09}$ e se encontra na área de rejeição da hipótese nula H_0 . Resta, portanto, a aceitação da hipótese alternativa, que indica que os valores de PSNR calculados nas seções de impedância acústica recuperadas com a CNN são estatisticamente superiores aos valores calculados nas seções obtidas com o método proposto por Pan et al. (2014b).

O teste seguinte comparou o modelo de CNN com o método proposto por Tofighi et al. (2016). Os resultados do teste t para essa comparação são apresentados na Tabela 8.

O p -valor para esse teste t é $1,4240^{-10}$ e se encontra na área de rejeição da hipótese nula H_0 . Assim como no caso anterior, a hipótese alternativa é aceita e indica que o modelo de CNN proposto é mais adequado para recuperar os detalhes de alta frequência das imagens de impedância invertida, que o método apresentado por Tofighi et al. (2016).

Cabe ressaltar que, aos olhos deste autor, é de grande relevância a comparação do método proposto neste trabalho com os métodos de aumento de resolução da inversão sísmica apresentados na revisão da literatura (Seção 3.4). Entretanto, a realização de tal procedimento tornou-se impedida por diferentes fatores como a indisponibilidade de código (fonte ou executável) dos métodos. Em relação ao método de escalonamento da *wavelet* (CHEN; WANG, 2018), observou-se uma limitação técnica na adaptação do código fonte⁴, necessária para atender ao contexto dos dados abordado neste trabalho.

5.5 CONSIDERAÇÕES FINAIS

O pico de razão sinal-ruído (PSNR), assim como o cálculo do espectro de frequências recuperadas, verificaram quantitativamente a qualidade do aumento de nitidez obtido com a CNN. Adicionalmente, foi possível verificar a adição de mais sinal de alta frequência e a diminuição do ruído nos traços processados pela rede. O cálculo do espectro de frequências permitiu verificar o percentual de recuperação de cada frequência em relação ao espectro da imagem de referência. Em comparação com os métodos de *deblurring* propostos recentemente por Pan et al. (2014b) e Tofighi et al. (2016), a abordagem unidimensional apresentou resultados consideravelmente superiores. Esses, foram verificados estatisticamente com o auxílio de testes *t-student*.

Os resultados dos experimentos indicam que é possível utilizar modelos de CNN para adicionar elementos de alta frequência perdidos durante o processo de inversão sísmica. Apesar do modelo proposto ter sido limitado à aplicação na inversão para a impedância acústica, a metodologia apresenta potencial realístico de aplicação para a inversão da porosidade. Certamente, há a vantagem de dispensar o processo de normalização dos dados. Em relação aos métodos de *deblurring* discriminativo, a CNN apresenta a vantagem de ser capaz de aprender diferentes formas de funções de *blurring* e ir além das suposições de normalidade e *motion blur*. Entretanto, essa capacidade está fortemente relacionada à disponibilidade de dados com tal variedade de aspectos borrados, o que, por sua vez, representa também uma limitação importante do método.

⁴ O código fonte do trabalho proposto por Chen e Wang (2018) foi disponibilizado pelos próprios autores.

6 CONCLUSÕES

Esta tese descreve os processo de construção, treinamento e aplicação de um modelo de Rede Neural Convolutacional (CNN) para realizar o aumento de nitidez em um conjunto de imagens de impedância acústica. O modelo permite a recuperação de elementos de alta frequência, eventualmente perdidos durante o processo de inversão sísmica. Para cumprir essa tarefa, a CNN realiza a inferência de um conjunto de filtros convolucionais por meio do aprendizado supervisionado. Por sua vez, a aprendizagem da rede ocorre com a utilização de pares de imagens de impedância acústica nítida e borrada como dados de entrada durante a fase de treinamento. Além do mais, este trabalho apresenta um *workflow* no qual o modelo de CNN é integrado ao processo de inversão sísmica como um método de pós-processamento.

Os principais trabalhos relacionados com o aumento de nitidez na inversão sísmica consistem no pré-processamento do dado sísmico, da *wavelet* ou de dados de perfis de poços. A aplicação dessas abordagens visa, principalmente, a manipulação dos dados mencionados, de modo a agregar-lhes conteúdo adicional de frequência antes da inversão propriamente. No entanto, não foram identificados trabalhos que foquem no pós-processamento da inversão sísmica.

A solução unidimensional apresentada nesta tese se mostrou viável computacionalmente. Foi possível aumentar a nitidez da impedância acústica invertida e corrigir as deformações de estruturas geológicas geradas durante o processo de inversão sísmica do conjunto de dados Stanford VI. Contudo, o caráter supervisionado da CNN torna a inferência dos filtros convolucionais dependente de um conjunto de impedância acústica nítida.

6.1 CONTRIBUIÇÕES

As principais contribuições deste trabalho incluem:

- Especificação de um *workflow* para o pós-processamento da inversão sísmica.
- Concepção de um *benchmark* para o treinamento e teste de modelos de ConvNet aplicados na inversão sísmica.
- Concepção de um modelo de ConvNet para realizar *deblurring* em imagens de impedância acústica invertida.
- Aplicação do modelo para incorporar elementos adicionais de alta frequência na impedância acústica invertida.
- Um estudo de caso aplicando o *workflow* nos dados Stanford VI.

6.2 PERSPECTIVAS FUTURAS

Naturalmente, este trabalho contemplou um escopo limitado e apresenta um potencial para a continuidade da pesquisa nos seguintes tópicos:

- Investigação da parametrização ótima do modelo através da aplicação de método de hiperparametrização, por exemplo, otimização Bayesiana ou busca em grade;
- Treinamento do modelo com dados de impedância acústica e sísmica de regiões rasas para a aplicação na recuperação da alta frequência em regiões profundas;
- Analisar o modelo unidimensional em um cenário de escassez de dados;
- Estudar o perfil sísmico obtido após a recuperação das altas frequências;
- Prototipar o modelo unidimensional;
- Investigar a aplicabilidade do método na inversão de outras propriedades, como porosidade.

6.3 PUBLICAÇÕES GERADAS

Por fim, durante o desenvolvimento deste trabalho foram geradas as seguintes produções:

- Publicação do artigo intitulado *Combined Convolutional Neural Network for High Frequency Restoration in Acoustic Impedance Images* (Sacramento et al., 2018). (Qualis-Capes: A1).
- Publicação do artigo intitulado *Acoustic Impedance Deblurring with a Deep Convolution Neural Network*. In: 31st Conference on Graphics, Patterns and Images (SIBGRAPI). Foz do Iguaçu, 2018.
- Publicação do artigo intitulado *Acoustic Impedance Deblurring with a Deep Convolution Neural Network* (Sacramento et al., 2019). (Qualis-Capes: A2).

REFERÊNCIAS

- ABDEL-HAMID, O. et al. Convolutional neural networks for speech recognition. **IEEE/ACM Transactions on audio, speech, and language processing**, n. 22, p. 1533–1545, 2014.
- ALREGIB, G. et al. Subsurface structure analysis using computational interpretation and learning: A visual signal processing perspective. **IEEE Signal Processing Magazine**, v. 35, n. 2, p. 82–98, Mar. 2018.
- BABACAN, S. D. et al. Bayesian blind deconvolution with general sparse image priors. In: **Computer Vision – ECCV 2012**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 341–355.
- BUDUMA, N. **Fundamentals of Deep Learning**. [S.l.]: Academic Press O’Reilly Media, 2015.
- BULAND, A.; OMRE, H. Bayesian linearized avo inversion. **GEOPHYSICS**, v. 68, n. 1, p. 185–198, 2003. Disponível em: <https://doi.org/10.1190/1.1543206>.
- CASTRO, S.; CAERS, J.; MUKERJI, T. **The Stanford VI reservoir: 18th Annual Report**. Stanford University, Stanford, CA, USA, 2005.
- CHAKRABARTI, A. A neural approach to blind motion deblurring. **CoRR**, Aug. 2016. Disponível em: <http://arxiv.org/abs/1603.04771>.
- CHANG, C.; HSIAO, J.; HSIEH, C. An adaptive median filter for image denoising. In: **Second International Symposium on Intelligent Information Technology Application**. [S.l.: s.n.], 2008. v. 2, p. 346–350.
- CHANG, S. G.; VETTERLI, M. Spatially adaptive wavelet thresholding with context modeling for image denoising. **IEEE Transactions on Image Processing**, v. 9, n. 9, p. 1522–1531, Sep. 2000.
- CHAUDHURI, S.; VELMURUGAN, R.; RAMESHAN, R. Blind deconvolution methods: A review. In: _____. **Blind Image Deconvolution: Methods and Convergence**. Cham: Springer International Publishing, 2014. p. 37–60.
- CHEN, S.; WANG, Y. Seismic resolution enhancement by frequency-dependent wavelet scaling. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 5, p. 654–658, May. 2018.
- CHOLLET, F. et al. **Keras**. 2015. <https://keras.io>.
- COOKE, D. et al. Model-based seismic inversion: Comparing deterministic and probabilistic approaches. **CSEG Recorder**, v. 35, n. 4, p. 29–39, 2010.
- DAHL, R.; NOROUZI, M.; SHLENS, J. Pixel recursive super resolution. **CoRR**, 2017. Disponível em: <http://arxiv.org/abs/1702.00783>.
- DANIELYAN, A.; KATKOVNIK, V.; EGIAZARIAN, K. Bm3d frames and variational image deblurring. **IEEE Transactions on Image Processing**, v. 21, n. 4, p. 1715–1728, Apr. 2012.
- DEUTSCH, C. V. **Geostatistical Reservoir Modeling**. Oxford University Press, 2002. (Applied geostatistics series). Disponível em: <https://books.google.com.br/books?id=1WvxAAAAMAAJ>.

DONG, C. et al. Image super-resolution using deep convolutional networks. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 38, n. 2, p. 295–307, Feb. 2014.

EATON, J. W. **GNU Octave Manual**. [S.l.]: Network Theory Limited, 2002.

FARFADE, S. S.; SABERIAN, M. J.; LI, L. Multi-view face detection using deep convolutional neural networks. In: **5th ACM on International Conference on Multimedia Retrieval**. [S.l.: s.n.], 2015. p. 643–650.

FARIAS, A. L.; FREITAS, L. B.; TYGEL, M. Detecção de camadas delgadas usando sísmica de reflexão. **Revista Brasileira de Geociências**, v. 38, n. 1, p. 159–171, 2008.

FIGUEIREDO, L. P. 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**, v. 336, p. 128 – 142, 2017.

FIGUEIREDO, L. P. de et al. Joint bayesian inversion based on rock-physics prior modeling for the estimation of spatially correlated reservoir properties. **Geophysics**, v. 83, n. 5, p. 49–61, 2018. Disponível em: <https://doi.org/10.1190/geo2017-0463.1>.

FIGUEIREDO, L. P. de et al. Bayesian framework to wavelet estimation and linearized acoustic inversion. **IEEE Geoscience and Remote Sensing Letters**, v. 11, n. 12, p. 2130–2134, Dec. 2014.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. <Http://www.deeplearningbook.org>.

GS IPL. **Seismic Surveys**. 2017. Disponível em: <http://geostar-surveys.com/methodology/20-HighResolutionSeismicSurveys.html>.

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn and TensorFlow**. [S.l.]: O'Reilly Media, 2017. (Academic Press).

HACOHEN, Y.; SHECHTMAN, E.; LISCHINSKI, D. Deblurring by example using dense correspondence. In: **IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2013. p. 2384–2391.

HARVEY, P. J.; MACDONALD, D. J. Seismic modelling of porosity within the jurassic aged carbonate bank, offshore nova scotia. **Canadian Journal of Exploration Geophysics**, n. 26, p. 54–71, 1999.

HE, K. et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. **CoRR**, abs/1502.01852, Aug. 2015. Disponível em: <http://arxiv.org/abs/1502.01852>.

HE, K. et al. Deep residual learning for image recognition. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 770–778.

HRADIŠ, M. et al. Convolutional neural networks for direct text deblurring. In: **Proceedings of the British Machine Vision Conference (BMVC)**. BMVA Press, 2015. p. 1–13. Disponível em: <https://dx.doi.org/10.5244/C.29.6>.

- HUNTER, J. D. Matplotlib: A 2d graphics environment. **Computing in Science & Engineering**, v. 9, n. 3, p. 90–95, 2007. Disponível em: <https://aip.scitation.org/doi/pdf/10.1109/MCSE.2007.55>.
- JAIN, V.; SEUNG, H. S. Natural image denoising with convolutional networks. In: **Proceedings of the 21st International Conference on Neural Information Processing Systems**. [s.n.], 2008. p. 769–776. Disponível em: <http://dl.acm.org/citation.cfm?id=2981780.2981876>.
- JJ, S. et al. Convolutional neural networks for human action recognition. **IEEE transactions on pattern analysis and machine intelligence**, n. 35, p. 221–231, 2013.
- JIANG, S.; HAO, X. Hybrid fourier-wavelet image denoising. **Electronics Letters**, v. 43, n. 20, p. 1081–1082, Sep. 2007.
- JIN, F. et al. Adaptive wiener filtering of noisy images and image sequences. In: **International Conference on Image Processing**. [S.l.: s.n.], 2003. v. 3, p. III–349.
- JUN, X.; BEI, Z. The high resolution pseudo impedance inversion and multi-information fusion in reservoir prediction. In: **2nd International Workshop on Database Technology and Applications**. [S.l.: s.n.], 2010. p. 1–4.
- KIM, J.; LEE, J. K.; LEE, K. M. Deeply-recursive convolutional network for image super-resolution. **CoRR**, abs/1511.04491, Mon 2015. Disponível em: <http://arxiv.org/abs/1511.04491>.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. **CoRR**, abs/1412.6980, 2014. Disponível em: <http://arxiv.org/abs/1412.6980>.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, p. 1097–1105, 2012.
- LAI, W. et al. A comparative study for single image blind deblurring. In: **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 1701–1709.
- LECUN, Y. Generalization and network design strategies. In: _____. **Connectionism in perspective**. [S.l.]: Elsevier, 1989.
- LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. In: **Proceedings of 2010 IEEE International Symposium on Circuits and Systems**. [S.l.: s.n.], 2010. p. 253–256.
- LEE, J.; MUKERJI, T. The stanford vi-e reservoir: A synthetic data set for joint seismic-em time-lapse monitoring algorithms. In: 25TH ANNUAL REPORT, STANFORD CENTER FOR RESERVOIR FORECASTING. [S.l.], 2012.
- LEVIN, A. et al. Efficient marginal likelihood optimization in blind deconvolution. In: **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2011. p. 2657–2664.
- LI, F.; LV, X.; DENG, Z. Regularized iterative weiner filter method for blind image deconvolution. **Journal of Computational and Applied Mathematics**, v. 336, p. 425–438, 2018. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0377042717306544>.

- LI, L. et al. Learning a discriminative prior for blind image deblurring. In: **Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2018. p. 6616–6625.
- LIU, L. et al. Seismic lithofacies computation method based on deep learning. In: _____. **International Geophysical Conference, Qingdao, China, 17-20 April 2017**. [s.n.], 2017. p. 649–652. Disponível em: <https://library.seg.org/doi/abs/10.1190/IGC2017-165>.
- MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier Nonlinearities Improve Neural Network Acoustic Models. 2013. Disponível em: http://web.stanford.edu/~{awni}/papers/relu_hybrid_icml2013_final.p.
- MAVKO, G.; MUKERJI, T.; DVORKIN, J. **The Rock Physics Handbook: Tools for Seismic Analysis of Porous Media**. [S.l.]: Cambridge, 2009. 359–369 p. (Cambridge University Press).
- MIN, C. et al. Blind deblurring via a novel recursive deep cnn improved by wavelet transform. **IEEE Access**, v. 6, p. 69242–69252, 2018.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: **Proceedings of the 27th International Conference on International Conference on Machine Learning**. USA: Omnipress, 2010. p. 807–814. Disponível em: <http://dl.acm.org/citation.cfm?id=3104322.3104425>.
- NARAYANAN, S.; THIRIVIKRAMAN, K. Image similarity using fourier transform. **International Journal of Computer Engineering & Technology (IJCET)**, v. 6, p. 29–37, Mar. 2015.
- NOSE-FILHO, K. et al. Improving sparse multichannel blind deconvolution with correlated seismic data: Foundations and further results. **IEEE Signal Processing Magazine**, v. 35, n. 2, p. 41–50, Mar. 2018.
- OH, S. et al. Salt delineation from electromagnetic data using convolutional neural networks. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 4, p. 519–523, Apr. 2019.
- OORD, A. van den et al. Conditional image generation with pixelcnn decoders. **CoRR**, abs/1606.05328, 2016. Disponível em: <http://arxiv.org/abs/1606.05328>.
- PAN, J. et al. Deblurring face images with exemplars. In: **European Conference Computer Vision – ECCV 2014**. Cham: Springer International Publishing, 2014. p. 47–62.
- PAN, J. et al. Deblurring text images via l0-regularized intensity and gradient prior. In: **2014 IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2014. p. 2901–2908.
- RUSSAKOVSKY, O. et al. Imagenet large scale visual recognition challenge. **International Journal of Computer Vision (IJCV)**, p. 211–252, 2015.
- RUSSELL, B. H. The Convolutional Model. In: **Introduction to Seismic Inversion Methods**. Society of Exploration Geophysicists, 1988. Disponível em: <https://dx.doi.org/10.1190/1.9781560802303.ch2>.
- RUSSELL, B. H. The Convolutional Model. In: **Introduction to Seismic Inversion Methods**. Society of Exploration Geophysicists, 1988. p. 54. Disponível em: <https://dx.doi.org/10.1190/1.9781560802303.ch2>.

- Sacramento, I. et al. Combined convolutional neural network for high frequency restoration in acoustic impedance images. In: **2018 International Joint Conference on Neural Networks (IJCNN)**. [S.l.: s.n.], 2018. p. 1–8.
- Sacramento, I. et al. Acoustic impedance deblurring with a deep convolution neural network. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 2, p. 315–319, Feb 2019.
- SANCEVERO, S. S.; REMACRE, A. Z.; PORTUGAL, R. S. O papel da inversão para a impedância no processo de caracterização sísmica de reservatórios. **Revista Brasileira de Geofísica**, v. 24, p. 495–512, 2006.
- SANCEVERO, S. S. et al. Comparing deterministic and stochastic seismic inversion for thin-bed reservoir characterization in a turbidite synthetic reference model of campos basin, brazil. **The Leading Edge**, v. 24, n. 11, p. 1168–1172, 2005.
- SCHMIDT, U.; SCHELTEN, K.; ROTH, S. Bayesian deblurring with integrated noise estimation. In: **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2011. p. 2625–2632.
- SCHULER, C. J. et al. Learning to deblur. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 38, n. 7, p. 1439–1451, Jul. 2016.
- SEN, M. K. **Seismic Inversion**. Richardson, TX, USA: Society of Petroleum Engineers, 2006. 69–73 p.
- SEN, M. K. **Seismic Inversion**. Richardson, TX, USA: Society of Petroleum Engineers, 2006. 11–12 p.
- SEN, M. K. **Seismic Inversion**. Richardson, TX, USA: Society of Petroleum Engineers, 2006.
- SUN, J.; PONCE, J. Learning a convolutional neural network for non-uniform motion blur removal. In: **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2015. p. 769–777.
- TARANTOLA, A. **Inverse Problem Theory and Methods for Model Parameter Estimation**. [S.l.]: Society for Industrial and Applied Mathematics, 2005.
- TOFIGHI, M. et al. Phase and TV Based Convex Sets for Blind Deconvolution of Microscopic Images. **IEEE Journal of Selected Topics in Signal Processing**, v. 10, n. 1, p. 81–91, Feb. 2016.
- WANG, C. et al. High-quality non-blind motion deblurring. In: **16th IEEE International Conference on Image Processing**. [S.l.: s.n.], 2009. p. 153–156.
- WANG, S. et al. Pseudo-acoustic inversion method and its application. In: **2010 Seventh International Conference on Fuzzy Systems and Knowledge Discovery**. [S.l.: s.n.], 2010. v. 2, p. 598–601.
- WANG, Y. The Ricker wavelet and the Lambert W function. **Geophysical Journal International**, v. 200, n. 1, p. 111–115, Nov. 2014. Disponível em: <https://doi.org/10.1093/gji/ggu384>.
- WINK, A. M.; ROERDINK, J. B. T. M. Denoising functional mr images: a comparison of wavelet denoising and gaussian smoothing. **IEEE Transactions on Medical Imaging**, v. 23, n. 3, p. 374–387, Mar. 2004.

XIAO, S. Blind image restoration algorithm based on l0 total-variation model. In: **14th IEEE International Conference on Signal Processing (ICSP)**. [S.l.: s.n.], 2018. p. 292–295.

XIAOYU, X. et al. Studying the effect of expanding low or high frequency on post-stack seismic inversion. In: _____. **SEG Technical Program Expanded Abstracts 2012**. [S.l.: s.n.], 2012. p. 1–5.

YUAN, S. et al. Simultaneous multitrace impedance inversion with transform-domain sparsity promotion. **GEOPHYSICS**, v. 80, n. 2, p. 71–80, 2015. Disponível em: <https://doi.org/10.1190/geo2014-0065.1>.

ZHANG, H.; WIPF, D.; ZHANG, Y. Multi-image blind deblurring using a coupled adaptive sparse prior. In: **2013 IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2013. p. 1051–1058.

ZHANG, R. et al. Stochastic and deterministic seismic inversion methods for thin-bed resolution. **Journal of Geophysics and Engineering**, v. 9, n. 5, p. 611–618, 2012. Disponível em: <http://stacks.iop.org/1742-2140/9/i=5/a=611>.

ZHOU, Y.; CHELLAPPA, R. Computation of optical flow using a neural network. In: **IEEE 1988 International Conference on Neural Networks**. [S.l.: s.n.], 1988. v. 2, p. 71–78.

ANEXO A – IMAGENS COMPARATIVAS

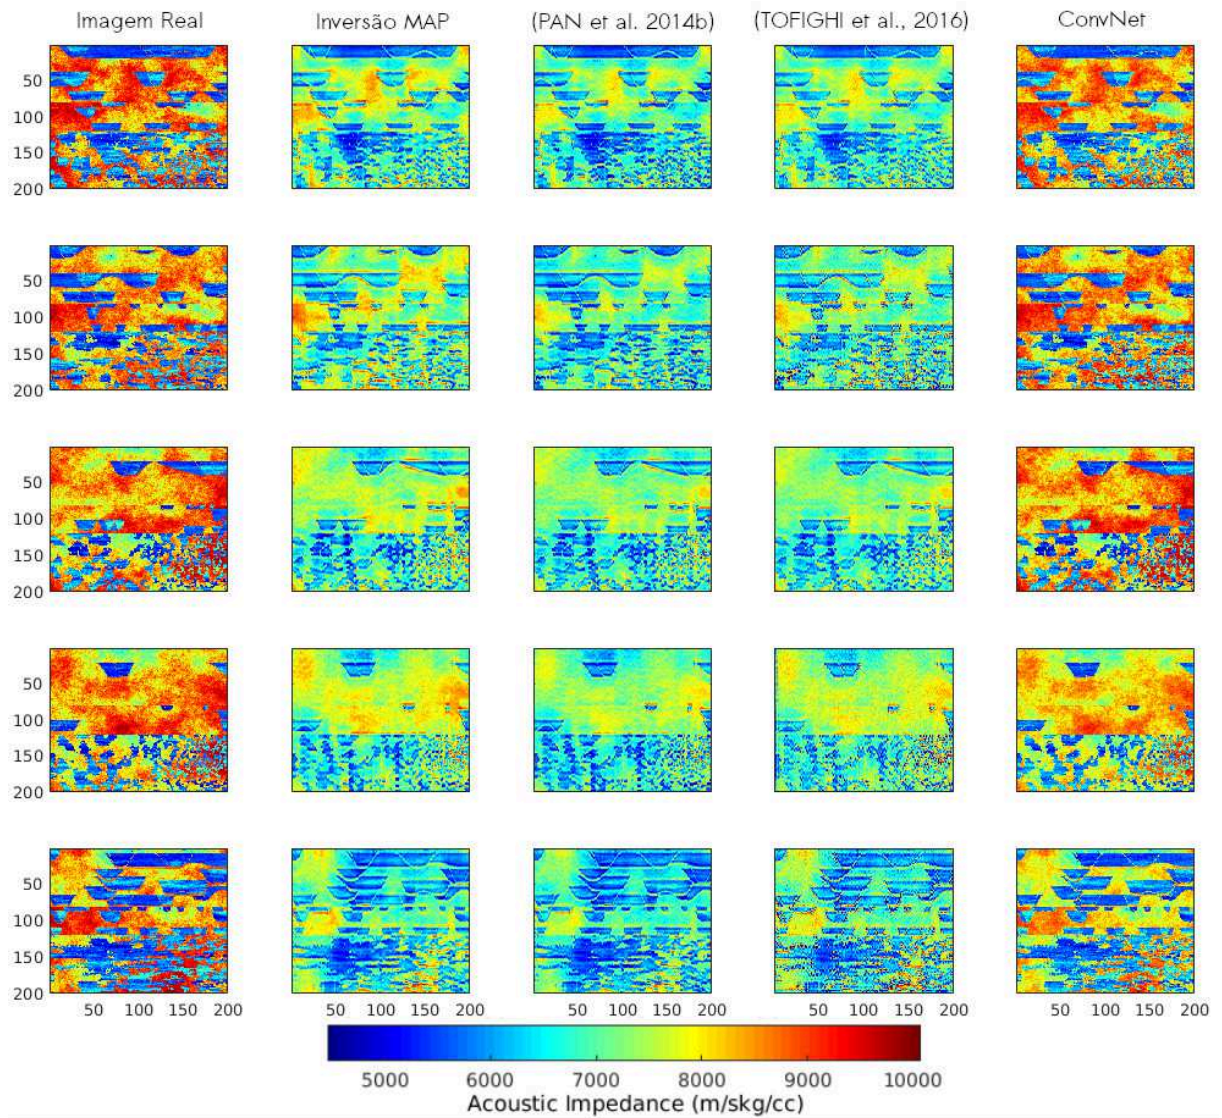


Figura 31 – *Deblurring* cego. (Imagem Real) - imagens consideradas a realidade. (Inversão MAP) - imagens em baixa resolução obtidas com método de inversão MAP. (PAN et al., 2014b) - método proposto por Pan et al. (2014b). (TOFIGHI et al., 2016) método proposto por Tofighi et al. (2016). (CNN) - imagens recuperadas com a CNN proposta neste trabalho. Fonte: o autor.

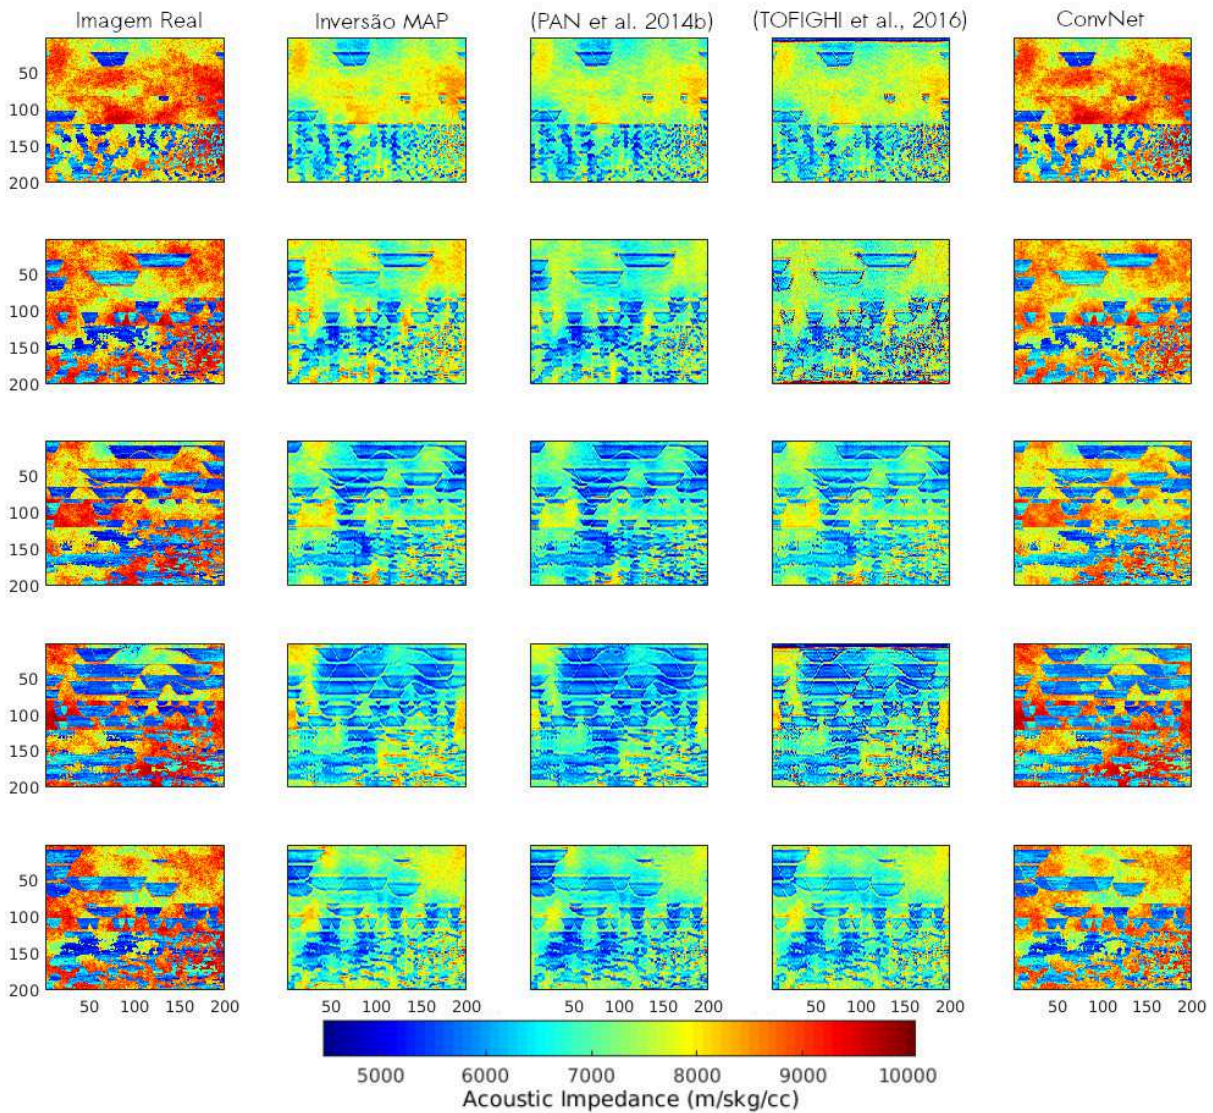


Figura 32 – *Deblurring* cego. (Imagem Real) - imagens consideradas a realidade. (Inversão MAP) - imagens em baixa resolução obtidas com método de inversão MAP. (PAN et al., 2014b) - método proposto por Pan et al. (2014b). (TOFIGHI et al., 2016) método proposto pro Tofighi et al. (2016). (CNN) - imagens recuperadas com a CNN proposta neste trabalho. Fonte: o autor.